



**T.C.**  
**MUŞ ALPARSLAN ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**R ORTAMI ÖZEL VERİ SETLERİNİ TAHMİN  
ETMEK İÇİN ZAMAN SERİSİ  
ALGORİTMALARINI HİBRİT MODELLERLE  
BİRLEŞTİRME**

**İbrahim Halil ÜNLÜK**

**YÜKSEK LİSANS TEZİ**

**Nükleer Enerji ve Enerji Sistemleri  
Anabilim Dalı**

**Ağustos-2022**  
**MUŞ**  
**Her Hakkı Saklıdır**



**T.C.**  
**MUŞ ALPARSLAN ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**R ORTAMI ÖZEL VERİ SETLERİNİ TAHMİN  
ETMEK İÇİN ZAMAN SERİSİ  
ALGORİTMALARINI HİBRİT  
MODELLERLE BİRLEŞTİRME**

**İbrahim Halil ÜNLÜK**

**YÜKSEK LİSANS TEZİ**

**Nükleer Enerji ve Enerji Sistemleri  
Anabilim Dalı**

**Danışman: Doç. Dr. Zeydin PALA**

**Ağustos-2022**  
**MUŞ**  
**Her Hakkı Saklıdır**

## TEZ KABUL ve ONAYI

İbrahim Halil ÜNLÜK tarafından hazırlanan “R ortamı özel veri setlerini tahmin etmek için zaman serisi algoritmalarını hibrit modellerle birleştirme” adlı tez çalışması .../.../... tarihinde aşağıdaki jüri tarafından oy birliği ile Muş Alparslan Üniversitesi Fen Bilimleri Enstitüsü Nükleer Enerji ve Enerji Sistemleri Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Dr. Öğr. Üyesi Yaşar DAŞDEMİR  
Erzurum Teknik Üniversitesi,  
Mühendislik ve Mimarlık Fakültesi,  
Bilgisayar Mühendisliği Bölümü

.....

#### Danışman

Doç. Dr. Zeydin PALA  
Muş Alparslan Üniversitesi,  
Mühendislik-Mimarlık Fakültesi,  
Yazılım Mühendisliği Bölümü

.....

#### Üye

Dr. Öğr. Üyesi İhsan TUĞAL  
Muş Alparslan Üniversitesi,  
Mühendislik-Mimarlık Fakültesi,  
Yazılım Mühendisliği Bölümü

.....

Yukarıdaki sonuç;  
Enstitü Yönetim Kurulu ...../...../..... Tarih ve ...../..... nolu kararı ile onaylanmıştır.

Doç. Dr. Sedat BOZARI  
FBE Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

İbrahim Halil ÜNLÜK

Tarih:

## ÖZET

### YÜKSEK LİSANS TEZİ

# R ORTAMI ÖZEL VERİ SETLERİNİ TAHMİN ETMEK İÇİN ZAMAN SERİSİ ALGORİTMALARINI HİBRİT MODELLERLE BİRLEŞTİRME

**İbrahim Halil ÜNLÜK**

**Muş Alparslan Üniversitesi  
Fen Bilimleri Enstitüsü  
Nükleer Enerji ve Enerji Sistemleri  
Anabilim Dalı**

**Danışman: Doç. Dr. Zeydin PALA**

Zaman serileri kullanılarak gelecek tahminlerinin yapılması tarihi çok eskilere dayanmaktadır. Sürekli izleme ve veri toplama daha yaygın hale geldikçe, hem istatistiksel hem de makine öğrenimi tabanlı zaman serisi analizine duyulan ihtiyaç artacaktır.

Zaman serisi modelleme ve tahmin analizi başta hava tahminleri olmak üzere ekonomi, sağlık, ilaç, enerji, astronomi, fizik, mühendislik ve daha birçok pratik uygulamada kullanılmaktadır. Kullanılan çoğu zaman serisi genellikle hem doğrusal hem de doğrusal olmayan bileşenleri içerebildiğinden dolayı, tek bir doğrusal veya doğrusal olmayan model söz konusu zaman serilerini modellemek ve tahmin etmek için yetersiz kalabilmektedir. Bu kısıtı aşmak için zaman serileri tahmin süreçlerinde tek model yerine işbirlikçi modeller kullanılarak tahmin sonuçları iyileştirilmeye çalışılmaktadır.

Bu çalışmada gerçekleştirilen zaman serisi tahmin analizlerinde dört farklı yaklaşım kullanılmıştır. Birinci yaklaşımda TBATS, ETS, THETAF, ARIMA, STLF ve NNTAR gibi istatistiksel ve derin öğrenme tabanlı tahmin modelleri tek başlarına kullanılmışlardır. Birinci yaklaşımda 8 adet yıllık zaman serisi, 3 adet mevsimsel zaman serisi ve 11 adet aylık zaman serisi olmak üzere toplam olarak 22 adet farklı zaman serisi kullanılarak gelecek tahminleri yapılmıştır. Geriye kalan diğer üç yaklaşım için birinci yaklaşımda tek başlarına kullanılan modellerin çoklu-hibrit model kombinasyonları kullanılmıştır. Çoklu-hibrit model kombinasyonu yaklaşım için tahmin işleminde görev alan modellerin katkıları sırasıyla eşit-ağırlıklı, değişken-ağırlıklı ve çapraz-doğrulama ağırlıklı alınarak gelecek tahminleri yapılmıştır. Çoklu-hibrit model yaklaşımlarının her biri için ikili, üçlü, dördü, beşli ve altılı modeller için sırasıyla 15, 20, 15, 6 ve 1 adet analiz yapılmıştır. Kombinasyon fonksiyonu yardımıyla her bir yaklaşım için 57 adet analiz ve üç farklı hibrit yaklaşımı için de 171 adet analiz yapılmıştır.

Farklı yaklaşımlar ile gerçekleştirilen gelecek tahmin analizlerinin performansları için hem popüler hem de yorumlanması oldukça kolay olan ortalama mutlak yüzde hata (MAPE) metriğinden faydalanılmıştır.

Yapılan analizler, çoklu-hibrit model kombinasyonları yardımıyla yapılan tahmin sonuçlarının tek başlarına kullanılan model tahmin sonuçlarından daha iyi olduğunu göstermektedir.

**2022, 38 Sayfa**

**Anahtar Kelimeler:** Zaman serileri, çoklu model tahmini, R derin öğrenme-tabanlı/istatistik-tabanlı modeller, R veri kümeleri

## ABSTRACT

## MS THESIS

# ENSEMBLING TIME SERIES ALGORITHMS WITH HYBRID MODELS TO PREDICT R ENVIRONMENT SPECIFIC DATASETS

**İbrahim Halil ÜNLÜK**

**Muş Alparslan University  
Natural and Applied Science  
Department of Nuclear Energy and Energy Systems**

**Advisor: Assoc. Prof. Dr. Zeydin PALA**

The history of making future predictions using time series dates back to ancient times. As continuous monitoring and data collection becomes more common, the need for both statistical and machine learning-based time series analysis will increase.

Time series modeling and forecasting analysis are used in many practical applications such as weather forecasts, economy, health, medicine, energy, astronomy, physics, engineering and many more. Since most of the time series used often contain both linear and nonlinear components, a single linear or nonlinear model may be insufficient to model and predict these time series. In order to overcome this limitation, it is tried to improve the estimation results by using collaborative models instead of a single model in time series estimation processes.

Four different approaches were used in the time series forecasting analysis performed in this study. In the first approach, statistical and deep learning based prediction models such as TBATS, ETS, THETAF, ARIMA, STLF and NNTAR are used alone. In the first approach, future predictions were made using a total of 22 different time series, including 8 annual time series, 3 seasonal time series and 11 monthly time series. For the remaining three approaches, multi-hybrid model combinations of the models used alone in the first approach were used. For the multi-hybrid model combination approach, future predictions were made by taking the contributions of the models involved in the estimation process equally-weighted, variable-weighted and cross-validated, respectively. For each of the multi-hybrid model approaches, 15, 20, 15, 6 and 1 analyzes were performed for the double, triple, quadruple, quintuple and six models, respectively. With the help of the combination function, 57 analyzes for each approach and 171 analyzes for three different hybrid approaches were performed.

The average absolute percent error (MAPE) metric, which is both popular and easy to interpret, was used for the performance of future forecast analyzes performed with different approaches.

The analyzes show that the prediction results made with the help of multi-hybrid model combinations are better than the model prediction results used alone.

**2022, 38 Pages**

**Keywords:** Time series, multi-model prediction, R deep learning-based/statistics-based models, R datasets

## TEŐEKKÖR

Bu alıőmada ncelikle benden vazgeemeyen cesaretlendiren ve tez boyunca yardımını esirgemeyen deęerli danıőman hocam Do. Dr. Zeydin PALA' ya, hayatımın her anında olan ve desteęini hibir zaman eksik etmeyen aileme teőekkör ederim.

İbrahim Halil ÖNLÖK  
MUŐ-2022



## İÇİNDEKİLER

ÖZET .....	iv
ABSTRACT.....	v
TEŞEKKÜR .....	vi
İÇİNDEKİLER .....	vii
SİMGELER ve KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ.....	xi
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>4</b>
<b>3. MATERYAL ve YÖNTEM .....</b>	<b>7</b>
3.1 Zaman Serisi Modelleri .....	7
3.1.1 Auto.Arima .....	7
3.1.2 ETS (Exponential Smoothing).....	7
3.1.3 Thetam (the theta model).....	8
3.1.4 NNTAR (Neural network time series forecasts).....	8
3.1.5 STLM.....	8
3.1.6 TBATS.....	8
3.1.7 HW (HOLT-WINTERS) .....	9
3.1.8 Naive Approach (Saf-Naif Yaklaşım) .....	9
3.1.9 MLP (Multilayer Perceptrons- Çok Katmanlı Algılayıcılar).....	9
3.1.10 ELM (Extreme Learning Machine - Aşırı Öğrenme Makinesi) .....	10
3.2 Zaman Serisi Tahmin Değerlendirme Metrikleri.....	10
3.2.1 RMSE (Root Mean Square Error- Ortalama Karekök Hatası) .....	10
3.2.2 MAE (Mean Absolute Error- Ortalama Mutlak Hatası) .....	10
3.2.3 MAPE (Mean Absolute Percentage Error- Ortalama Mutlak Yüzde Hatası)....	11
3.2.4 MASE (Mean Absolute Scaled Error- Ortalama Mutlak Ölçekli Hatası) .....	11
<b>4. ARAŞTIRMA SONUÇLARI ve TARTIŞMA .....</b>	<b>13</b>
4.1 Tek Model Kullanılarak Yapılan Tahminler .....	13
4.2 Hibrit Model Kullanılarak Yapılan Tahminler .....	20
4.2.1 Hibrit Model Kullanılarak Farklı Katkıya Sahip Yapılan Tahminler .....	20
4.2.2 Hibrit Model Kullanılarak Eşit Katkıya Sahip Yapılan Tahminler .....	26
4.2.3 Hibrit Model Yardımıyla Çapraz-Doğrulama Kullanılarak Yapılan Tahminler	28
<b>5. SONUÇLAR ve ÖNERİLER.....</b>	<b>31</b>
5.1 Sonuçlar .....	31
5.1.1 Tek Model Kullanılarak Yapılan Tahmin Sonuçları .....	31
5.1.2 Hibrit Model Kullanılarak Farklı Katkıya Sahip Yapılan Tahmin Sonuçları....	32

5.1.3 Hibrit Model Kullanılarak Eşit Katkıya Sahip Yapılan Tahmin Sonuçları .....	33
5.1.4 Hibrit Model Yardımıyla Çapraz-Doğrulama Kullanılarak Yapılan Tahmin Sonuçları .....	34
5.2 Öneriler .....	36
<b>KAYNAKLAR .....</b>	<b>37</b>



## SİMGELELER ve KISALTMALAR

### Kısaltmalar

ADF	: Augmented Dickey-Fuller Test
MAPE	: Mean Absolute Percentage Error
MASE	: Mean Absolute Scaled Error
MAE	: Mean Absolute Error
RMSE	: Root Mean Squared Error
STL	: Seasonal and Trend Decomposing Time Losess
SES	: Simple Exponential Smoting
TBATS	: Exponential smoothing state space model with Box-Cox transformation, ARMA errors, Trend and Seasonal components
THETA F	: Theta method forecast
ARIMA	: Auto Regressive Integrated Moving Average
ELM	: Extreme learning machine
ETS	: Exponential Smoting
MLP	: Multiplayer Perceptrons
NNAR	: Neural Network Autoregression
SVM	: Support Vector Machine
NN	: Neural network
LSTM	: Long / Short Term Memory
ANN	: Artificial Neural Network
VMD	: Variable Mode Decomposition
DBN	: Deep Belief Network
MEB	: Maximum Entropy Bootstrap
HW	: HOLT-WINTERS

## ŞEKİLLER DİZİNİ

<b>Şekil 4.1</b> Hybridmodel kullanılarak ikili grupta en iyi tahmini yapan “fn” modeline ait tahmin grafiği.....	24
<b>Şekil 4.2</b> Hybridmodel kullanılarak üçlü grupta en iyi tahmini yapan “aen” modeline ait tahmin grafiği.....	24
<b>Şekil 4.3</b> Hybridmodel kullanılarak dördü grupta en iyi tahmini yapan “afnt” modeline ait tahmin grafiği.....	25
<b>Şekil 4.4</b> Hybridmodel kullanılarak beşli grupta en iyi tahmini yapan “aefnt” modeline ait tahmin grafiği.....	25
<b>Şekil 4.5</b> Hybridmodel kullanılarak altılı grupta en iyi tahmini yapan “aefnst” modeline ait tahmin grafiği.....	26



## ÇİZELGELER DİZİNİ

<b>Çizelge 4.1</b> Aylık, yıllık ve mevsimlik zaman serilerine ait istatistiksel bilgiler .....	13
<b>Çizelge 4.2</b> 10 farklı modelin tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE metrik değerlerinin zaman serisi bazında sıralanışı.....	14
<b>Çizelge 4.3</b> 22 adet zaman serisi için kullanılan 10 ayrı modelden en iyi üç tanesinin MAPE ortalama değerlerinin MAPE bazından küçüğe doğru sıralanışı .....	19
<b>Çizelge 4.4</b> HybridModel ile yapılan değişken ağırlıklı ikili model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	21
<b>Çizelge 4.5</b> HybridModel ile yapılan değişken ağırlıklı üçlü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	21
<b>Çizelge 4.6</b> HybridModel ile yapılan değişken ağırlıklı dördü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	22
<b>Çizelge 4.7</b> HybridModel ile yapılan değişken ağırlıklı beşli model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	22
<b>Çizelge 4.8</b> HybridModel ile yapılan değişken ağırlıklı altılı model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	23
<b>Çizelge 4.9</b> HybridModel ile yapılan eşit ağırlıklı ikili model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali .....	26
<b>Çizelge 4.10</b> HybridModel ile yapılan eşit ağırlıklı üçlü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali .....	27
<b>Çizelge 4.11</b> HybridModel ile yapılan eşit ağırlıklı dördü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	27
<b>Çizelge 4.12</b> HybridModel ile yapılan eşit ağırlıklı beşli model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali .....	28
<b>Çizelge 4.13</b> HybridModel ile yapılan eşit ağırlıklı altılı model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali .....	28
<b>Çizelge 4.14</b> HybridModel ile yapılan çapraz-doğrulama ikili model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	28
<b>Çizelge 4.15</b> HybridModel ile yapılan çapraz-doğrulama üçlü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	29
<b>Çizelge 4.16</b> HybridModel ile yapılan çapraz-doğrulama dördü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	29
<b>Çizelge 4.17</b> HybridModel ile yapılan çapraz-doğrulama beşli model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçüğe doğru sıralanmış hali.....	30

**Çizelge 4.18** HybridModel ile yapılan çapraz-doğrulama altılı tahminlere ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali ..... 30



## 1. GİRİŞ

İlk olarak zaman serisinin tanımını yapmak gerekir. Bir zaman serisi, eşit zaman aralıklarında gözlemlenebilir bir  $y$  değişkeninin tarihsel ölçümlerinin  $yi$  dizisidir. Bu aralıklar örneğin saat, gün, hafta veya yıl olarak yansıtılabilir. Zaman serisi örnekleri çeşitlidir ve bir günde güneşlenme saatlerini veya bir şirketin günlük hisse senedi fiyatlarını içerir. Zaman serilerinin temel bir özelliği, gözlemleri arasında bir ilişki olmasıdır. Örneğin, dün ölçülen sıcaklık bugünün sıcaklığını etkiler. Bir zaman serisinin gecikmeli değerleri arasındaki bu ilişkiye otokorelasyon denir. Bu bağlamdan, geçmiş değerlerin tahmin potansiyeline sahip olabileceği sonucu çıkar. (Palit & Popovic, 2005)

Zaman serisi modelleme ve tahmin işlemi, çeşitli pratik alanlar için temel öneme sahiptir. Literatürde zaman serisi modelleme ve tahminlerinin doğruluğunu ve verimliliğini artırmak için birçok önemli model önerilmiştir. Zaman serisi verileri ve analizleri, örneğin nesnelere interneti, sağlık hizmetlerinin dijitalleşmesi ve akıllı şehirlerin yükselişi yoluyla bu tür verilerin büyük miktarda üretilmesi nedeniyle giderek daha önemli hale gelmektedir (Pala ve ark., 2019).

Tahmin kalitesini artırmak için modelleri tek başına kullanmak yerine bazı modellerin kombinasyonları ile tahmin yapmak daha iyi bir yaklaşım tarzı olarak karşımıza çıkmaktadır. Çünkü aynı anda bir zaman serisinin eğilim ve mevsimsellik gibi özelliklerini işleyebilirler, ancak tahminciler için önerilenler arasından en iyi modeli seçmek her zaman kolay değildir. Zaman serileri genellikle farklı nitelikte olabilmekte ve dış faktörlerin etkileri bir modelden diğerine farklılık gösterebilmektedir. Tahmin amaçları için en uygun modeli seçmek, nitel deneyimin yanı sıra tahminler ve zaman serisi doğası konusunda da kapsamlı deneyim gerektirir. Birçok bilimsel araştırmada, tek bir tekniğin, bazı tekniklerin bir kombinasyonundan daha iyi bir öngörücü niteliğinin olmadığı kabul edilmektedir (Gjika et al., 2019).

Toplu öğrenme özel bir makine öğrenmesi konusudur. Genel olarak daha yüksek doğruluk ve istikrarlı model performansı sağlamak amacıyla birden fazla modeli bir araya getirme girişimidir. Geçmişten günümüze topluluk metodolojisi sağlam teoriye dayanmaktadır ve kullanımı karmaşık veri bilimi senaryolarında başarılı uygulamalarda kullanılmıştır (Tattar, 2018). Topluluk teknikleri, son on yılda istatistiksel ve makine öğrenimi alanında gelişen model çıktı toplama teknikleri olarak karşımıza çıkmaktadır.

Popüler makine öğrenimi algoritmalarının hiçbiri zaman serisi tahmini için oluşturulmamıştır ve tahmin için kullanılmaları için zaman serisi verilerinin önceden işlenmesi yani hazır hale getirilmesi gerekmektedir (Smyl, 2020).

Makine öğrenimi algoritmalarının gücü çapraz doğrulamaya dayanmaktadır. Yani tek bir modeli eğitmek için serinin tamamı farklı bölümler halinde kullanılmaktadır. Ancak bu durum her seri için ayrı bir modelin geliştirildiği standart istatistiksel zaman serisi algoritmalarından farklıdır (Pala ve Özkan, 2020).

Pratik araştırmalarda, deneyleri tasarlamak veya hâlihazırda toplanmış verileri analiz etmek için profesyonel istatistiksel yazılımlar kullanılır. Bu çalışmada R yazılım paketlerini kullandık. R, son birkaç on yılda bilimsel hesaplama görevleri için oldukça iyi bir araç olarak ortaya çıkmış ve verileri analiz etmek için istatistiksel metodolojilerin uygulanmasında tutarlı bir yer edinmiştir.

Tahmin işlemlerinde topluluk zaman serisi modellerini kullanmak için öncelikle Hibrit model kütüphanesini R programlama ve geliştirme ortamına dâhil etmek gerekmektedir. R geliştirme ortamının hibrit paketi, heterojen zaman serisi modellerini bir araya getirmek için uygun bir platform sağlamaktadır. Bu görevi sağlayan ana işlev, `hybridModel` işlevidir. Bu model girdi olarak altı karaktere kadar bir dizgi almakta ve karakterlerin her biri bir modeli temsil etmektedir. Örneğin `auto.arima` modeli için `a`, `ets` için `e`, `thetam` için `f`, `nnetar` için `n`, `stlm` için `s` ve son olarak, `tbats` için `t` karakteri kullanılmaktadır.

Zaman serilerinin farklı yapılarından kaynaklanan ilişkileri daha iyi analiz etmek ve yüksek doğruluklu gelecek tahminleri yapabilmek için çoklu algoritmaların tekli algoritmalarından daha iyi olup olmadığını kanıtlamayı bir problem olarak kabul ettik ve bunun için çoklu-hibrit modeli önerdik.

R geliştirme ortamı zaman serileri kullanılarak yapılan kısa vadeli tahmin analizlerinde hibrit modellerin daha iyi bir tahmin performansına sahip olduğunu kanıtlamaktadır. Bu çalışmanın dört ana katkısı şu şekilde özetlenebilir:

(1) Yapılan tahmin analizlerinde `auto.arima`, `ets`, `thetam`, `nnetar`, `stlm` ve `tbats` gibi istatistik-tabanlı ve derin öğrenme-tabanlı modellerinin farklı kombinasyonları kullanılmıştır.

(2) Tek başına kullanılan modellerle karşılaştırıldığında, bu çalışmada önerilen yeni hibrit modelin daha yüksek doğruluğa ve daha güçlü kararlılığa sahip olduğu kanıtlanmıştır.

(3) Önerilen hibrit model ile yapılan kısa vadeli tahmin işlemlerinde daha düşük MAPE değerleri ve daha yüksek doğruluk elde edilmiştir.

(4) Hibrit modeller kullanılırken değişken-katkılı, eşit-katkılı ve çapraz doğrulama-katkılı yaklaşımları ile yapılan tahminler karşılaştırılmıştır (Pala ve Atıcı, 2019).



## 2. KAYNAK ARAŞTIRMASI

Literatürde tahmin modelleri genel anlamda üç kategoride sınıflandırılmıştır. Birinci grup, zaman serileri (Zeydin Pala, 2021; Zeydin Pala & Atici, 2019; Zeydin Pala & Özkan, 2020; Zeydin Pala & Pala, 2021; Zeydin Pala & Şana, 2020) yâda istatistik-tabanlı yöntemler (Makridakis et al., 2018) olarak sınıflandırılırken, ikinci grup, yapay zekâ tabanlı yöntemler (makine öğrenmesi (Z. Pala et al., 2019), derin öğrenme (Långkvist et al., 2014) , genetik algoritma (Gidon et al., 2019) olarak sınıflandırılmaktadır. Son grup ise istatistik ve derin öğrenme tabanlı yâda genetik algoritmalar ile diğer modellerin kombinasyonu biçiminde (Makridakis, S., Spiliotis, E., Assimakopoulos, 2018) hibrit yöntemler olarak sınıflandırılabilir.

Yapay zekâ tabanlı modeller 1992-2006 yılları arasında popüler olmaya başlamış, destek vektör makinelerinin yoğun kullanılması yapay zekâ alanında makine öğrenmesinin de gelişmesine katkı sağlamıştır. Ayrıca istatistiksel modellerle karşılaştırıldığında, makine öğrenimi modelleri, karmaşık doğrusal olmayan verilerin işlenmesinde, özellikle kısa süreli doğal gaz tüketim tahmininde yüksek doğrulukta belirgin avantajlara sahiptir (Liu et al., 2021).

Son yıllarda, giderek daha fazla bilim insanı, bulanık teori modelleri, destek vektör makinesi (SVM) modelleri ve sinir ağı (NN) gibi akıllı algoritmaları kullanmaya başladı. Akıllı algoritmaların geleneksel algoritmalarından daha fazla avantajı olmasına rağmen, uzun hesaplama süresi, yavaş yakınsama hızı, erken yakınsamanın kolay olması gibi bazı kaçınılmaz dezavantajları da vardır. Bu nedenle, optimizasyon tahmin modeli hala üzerinde yoğun olarak çalışılan bir araştırma konusudur (Qiao et al., 2019).

Son dönemde hibrid modeller zaman serileri tahmin işlemleri için araştırmacılar tarafından yoğun olarak kullanılmıştır.

Smyl ve arkadaşları M4 yarışması için yaptıkları çalışmalarında üstel yumuşatma (exponential smoothing) modelini gelişmiş uzun kısa süreli bellek (LSTM) sinir ağlarıyla ortak bir çerçevede karıştıran bir hibrit tahmin yöntemini önermişlerdir. Üstel yumuşatma denklemleri, yöntemin mevsimsellik ve seviye gibi bireysel serilerin ana bileşenlerini etkin bir şekilde yakalaması için kullanılırken, LSTM ağları doğrusal olmayan eğilimlere ve çapraz öğrenmeye izin vermek için kullanılmıştır (Smyl, 2020).

Zhang ve arkadaşları çalışmalarında, doğrusal ve doğrusal olmayan modellemede ARIMA ve ANN (Artificial neural network) modellerini birleştiren bir hibrit metodoloji önermişlerdir. Gerçek veri kümeleriyle yapılan deneysel sonuçlar, birleştirilmiş modelin,

ayrı ayrı kullanılan modellerden herhangi biri tarafından elde edilen tahmin doğruluğunu daha da iyileştirdiği sonucuna varmışlardır (Zhang, 2003).

Ma ve arkadaşları çalışmalarında temel bir istatistiksel zaman serisi modeli ile bir makine öğrenimi algoritmasının birleştirerek kullanmışlardır. Daha spesifik olarak, NN-ARIMA olarak adlandırılan bir ARIMA modeli ile temel bir sinir ağı modelini sıralı olarak birleştirmişlerdir. Deneysel sonuçlara göre, önerilen yaklaşım, ortalama karesel hatayı önemli ölçüde azalttığını ve böylece tahminin doğruluğunu iyileştirdiğini göstermişlerdir (Ma et al., 2020).

Castillo ve arkadaşları çalışmalarında zaman serilerine dayalı olarak on ülke için doğrulanmış covid-19 vakaları ve ölümleri tahmin etmek için bir hibrit bulanık fraktal yaklaşımı önermişlerdir (Castillo & Melin, 2020).

Li ve arkadaşları çalışmalarında değişken mod ayrıştırma (VMD), parçacık sürüsü optimizasyonu (PSO) ve derin inanç ağı (DBN) tabanlı aylık Henry Hub doğal gaz fiyatlarının hibrit bir tahmin modelini önermişlerdir (Li et al., 2021).

Gao ve arkadaşları yaptıkları çalışmada yıllık doğal gaz tüketimini tahmin etmek için destek vektör makinesine ve geliştirilmiş yapay balık sürüsü algoritmasına dayalı yeni bir hibrit tahmin modeli önermişlerdir. Atıcı ve Pala, Ionospheric foF2 parametre tahmini için çalışmalarında hibrit modeli kullanmışlardır (Atıcı & Pala, 2021). Qiao ve arkadaşları saatlik gaz tüketimi için çalışmalarında hibrit bir model önermişlerdir (Qiao et al., 2019). Tseng ve arkadaşları mevsimsel özelliğe sahip zaman serilerini tahmin etmek için hibrit bir gri model önermişlerdir (Tseng et al., 2001).

Chang ve arkadaşları elektrik fiyatı tahmini için yeni bir hibrit model önermişlerdir. Yazarlar çalışmalarında Adam optimize edilmiş LSTM sinir ağı ve dalgacık dönüşümüne dayalı hibrit bir model önermişlerdir (Chang et al., 2019). Du ve arkadaşları yaptıkları çalışmada kısa vadeli rüzgâr enerjisi tahmini için yeni bir hibrit model önermişlerdir. Çalışmalarının odak noktasını tahmin doğruluğu ve kararlılığının iyileştirilmesi, tek adımlı ve çok adımlı rüzgâr enerjisi tahmini ve tahmin modellerinin kapsamlı performans doğrulaması konuları oluşturmuştur (Du et al., 2019).

Meira ve arkadaşları çalışmalarında bootstrap aggregation (Bagging), tek değişkenli zaman serisi tahmin yöntemlerini ve değiştirilmiş regularization rutinlerini birleştirmişlerdir. Maximum Entropy Bootstrap (MEB) ve veri oluşturma sürecinin toplulukta tutulmasını sağlayan değiştirilmiş bir regularization rutini kullanan yeni bir bagging çeşidi tanıtmışlardır (Meira et al., 2022).

Yukardaki alıřmalardan farklı olarak bu alıřmada aynı zaman serisi üzerinde daha yksek doęruluk ve kararlılık elde etmek iin R geliřtirme ortamının HybridModel ktphanesi nerilmektedir. nerilen sistem drt farklı yaklařımdan oluřmaktadır: Bunlardan birisi baęımsız modellerin tahmin iřleminde tek bařlarına rol aldıkları bir yaklařım olarak kullanılırken, ikinci, nc ve drdnc yaklařımlar hibrit tabanlı olarak sırasıyla deęiřken-katkılı, eřit-katkılı ve apraz-doęrulama katkılı olarak kullanılmaktadır.



### 3. MATERYAL ve YÖNTEM

Bu bölümde öncelikle 22 adet zaman serisi tahmin işleminde tek başlarına kullanılan ETS, STL, HOLT-WINTERS, ARIMA, THETAM, TBATS, NAIVE, NNTAR, MLP ve ELM modelleri kısaca tanıtılmıştır. Bu modellerin altısı aynı zamanda HybridModel kütüphanesi vasıtasıyla kullanılmaktadır. Çoklu-hibrit tahminlerde sadece bu altısı kullanılmıştır. Bunlar auto.arima (a), ets (e), thetam (f), nnetar (n), stlm (s) ve tbats (t) modellerinden oluşmaktadır (Atıcı & Pala, 2022).

Bu bölümün sonunda model performanslarını değerlendirmek için kullanılan RMSE, MAE, MAPE ve MASE metrikleri kısaca açıklanmıştır.

#### 3.1 Zaman Serisi Modelleri

##### 3.1.1 Auto.Arima

ARIMA (p,d,q), zaman serisi verilerini tahmin etmek için çok güçlü bir model olmasına rağmen, veri hazırlama ve parametre ayarlama süreçleri gerçekten zaman alıcıdır. Burada p otomatik regresyon sırası, d trend farkının derecesi ve q hareketli ortalamayı ifade etmektedir. ARIMA'yı uygulamadan önce seriyi durağan hale getirip p ve q değerlerini belirlememiz gerekiyor. Auto ARIMA, otoregresif ve hareketli ortalama bileşenlerin sıralarını tahmin etme adımlarını ortadan kaldırdığı için bu görevi bizim için basitleştirir. Auto ARIMA, en iyi parametre kombinasyonunu belirlemek için oluşturulan AIC ve BIC değerlerini dikkate alır. AIC (Akaike Information Criterion) ve BIC (Bayesian Information Criterion) değerleri, modelleri karşılaştırmak için tahmin edicilerdir (Ma et al., 2020). Bu değerler ne kadar düşükse model o kadar iyidir.

##### 3.1.2 ETS (Exponential Smoothing)

ETS, tek değişkenli veriler için bir zaman serisi tahmin yöntemidir. Box-Jenkins ARIMA yöntem ailesi gibi zaman serisi yöntemleri, tahminin yakın geçmişteki gözlemlerin veya gecikmelerin ağırlıklı doğrusal toplamı olduğu bir model geliştirir. ETS tahmin yöntemleri, bir tahminin geçmiş gözlemlerin ağırlıklı bir toplamı olması bakımından benzerdir, ancak model açıkça geçmiş gözlemler için katlanarak azalan bir ağırlık kullanır. Spesifik olarak, geçmiş gözlemler geometrik olarak azalan bir oranla ağırlıklandırılır (Panigrahi & Behera, 2017).

### 3.1.3 Thetam (the theta model)

THETAM modeli, "Ekstrapolatif bir yöntem, bir zaman serisinde saklı olan tüm mevcut bilgileri verimli bir şekilde yakalama konusunda pratik olarak yetersizdir" düşüncesinden türetilen bir zaman serisi tahmin modelidir. Bir yandan mevcut tüm bilgileri yakalamak için çok basit modeller var. Öte yandan, daha zorlu temel kalıplarla başa çıkmak için daha fazla parametrenin kullanıldığı yöntemler vardır; ne yazık ki, tüm bu parametreleri optimize ederken, genellikle bu karmaşık yöntemler, gerçek verilere aşırı uyum sağlar. Dolayısıyla bu yaklaşım, modellerin verileri yakalamasına yardımcı olmayı amaçlamaktadır. Bu veriler, her biri orijinal seride yer alan bilgilerin bir kısmını yakalayan birkaç basit seriye bölerek elde edilir. Böylece, özünde bir ayrıştırma yaklaşımı kullanılmaktadır. Bu sürecin bir sonucu olarak, daha basit modeller daha basit serilere uyum sağlayabilir (Makridakis et al., 2018).

### 3.1.4 NNTAR (Neural network time series forecasts)

R için tahmin paketindeki NNETAR işlevi, girdiler ve muhtemelen diğer bazı dışsal girdiler olarak zaman serisinin gecikmeli değerlerine sahip bir zaman serisinin sinir ağı modelini eğitmektedir. Dolayısıyla, doğrusal olmayan bir otogresif modeldir ve analitik olarak tahmin aralıklarını türetmek mümkün değildir. Ağ, tek adımlı tahmin için eğitilmiştir. Çok adımlı tahminler özyinelemeli olarak hesaplanır. Mevsimsel olmayan veriler için, takılan model bir NNAR(p, k) modeli olarak belirtilir; burada p girdi olarak kullanılan mevsimsel gecikmelerin sayısını gösterirken k ise gizli düğümlerin sayısını göstermektedir (Ma et al., 2020).

### 3.1.5 STLM

STLM bir y zaman serisini alır, bir STL ayrıştırması uygular ve mevsimsellikten arındırılmış verileri model işlevi olarak geçirilen veya yöntem kullanılarak belirtilen modeli kullanarak modeller. Orijinal STL ayrıştırmasını içeren bir nesneyi ve mevsimsel olarak ayarlanmış verilere uyan bir zaman serisi modelini döndürür (Hyndman and Athanasopoulos, 2019).

### 3.1.6 TBATS

TBATS modeli artıklar için "Trigonometrik Mevsimsel + Üstel Düzeltme Yöntemi + Box-Cox Dönüşümü + ARMA" modelidir. Buradaki Box-Cox Dönüşümü, doğrusal olmayan verilerle uğraşmak içindir ve artıklar için ARMA modeli, zaman serisi

verileriyle ilişkilendirilebilir. TBATS modeli, basit durum uzayı modeline kıyasla tahmin performansını iyileştirebilir. Mevsimsellik terimlerinin trigonometrik ifadesi, yalnızca mevsimsellik sıklıkları yüksek olduğunda modelin parametrelerini önemli ölçüde azaltmakla kalmaz, aynı zamanda modele karmaşık mevsimsellik ile başa çıkmak için daha fazla esneklik sağlar (Hyndman and Athanasopoulos, [2019](#); Du ve ark., 2019).

### 3.1.7 HW (HOLT-WINTERS)

Holt-Winters' Yönteminin (HW), araştırmacılar çok popüler olan üssel ağırlıklı hareketli ortalama yönteminin, yalnızca bir zaman serisinin seviyesini düzleştirmek için değil, aynı zamanda eğilim ve mevsimselliği de düzleştirmek için kullanılabileceğini gösterdi. Bu yöntemin, mevsimsel bileşenleri dahil ederek ve bu nedenle üç düzleştirme denkleminin sahip olarak Holt'un Doğrusal Yöntemini genişlettiğinden, bazen Üç Üstel Düzleştirme (Triple Exponential Smoothing) olarak adlandırılır. Üstel yumuşatma yöntemleri ve ilgili Holt-Winters Yöntemi, zaman serisi tahmini için yaygın olarak kullanılan yaklaşımlardır (Hyndman and Athanasopoulos, [2019](#)).

### 3.1.8 Naive Approach (Saf-Naif Yaklaşım)

Bu yaklaşım, bugünün değerinin yarının değeri olacağını varsayan bir prosedürdür. Yöntemin basit olmasına rağmen, birçok ekonomik ve finansal zaman serisi için oldukça iyi çalışır.

Mevsimsel naive yaklaşım, naive yaklaşımın bir çeşididir ve oldukça mevsimsel veriler için kullanışlıdır. Her tahmini, bir önceki yılın aynı sezonundaki son gözlemlenen değere eşit olarak ayarlar. Örneğin, aylık veriler söz konusu olduğunda, bu yılın Mayıs ayı değeri tahmin edilirken, değer önceki yıl o aydaki değere ayarlanır.

Naive yaklaşımlar basittir ancak şaşırtıcı derecede etkili olabilir. Genellikle, diğer yöntemleri karşılaştırmak için kullanılan temel yöntemler veya kıyaslamalar olarak kabul edilirler. Daha gelişmiş bir yöntem daha iyi sonuçlar alamıyorsa, dikkate almaya değmez (Hyndman and Athanasopoulos, [2019](#)).

### 3.1.9 MLP (Multilayer Perceptrons- Çok Katmanlı Algılayıcılar)

Tek bir nöron karmaşık, doğrusal olmayan ilişkileri modellemek için yeterli değildir. Bu nedenle, nöron ağları kullanılmalıdır. Bu ağlar, bir katman oluşturan dikey nöron yığınlarından ve bunlar arasındaki bağlantılardan oluşur. Birkaç katmana sahip

ağlar, Çok Katmanlı Algılayıcılar (MLP) veya İleri Beslemeli Sinir Ağları (FFNN) olarak adlandırılır (Hyndman and Athanasopoulos, [2019](#)).

### 3.1.10 ELM (Extreme Learning Machine - Aşırı Öğrenme Makinesi)

Aşırı öğrenme makinesinde, gizli düğümler rastgele başlatılır ve daha sonra yinelemeli olarak ayarlanmadan sabitlenir. Aslında, aşırı öğrenme makinesindeki gizli düğümlerin aynı nöron olması bile gerekli değildir. Öğrenilmesi gereken tek serbest parametre, gizli katman ile çıktı katmanı arasındaki bağlantılar (veya ağırlıklardır). Bu şekilde aşırı öğrenme makinesinde, doğrusal bir sistemi çözmeye indirgenen parametre içinde doğrusal bir model olarak formüle edilir. Geleneksel öğrenme yöntemleriyle karşılaştırıldığında, ELM (aşırı öğrenme makinesi) oldukça verimlidir ve küresel bir optimuma ulaşma eğilimindedir (Hyndman and Athanasopoulos, [2019](#)).

## 3.2 Zaman Serisi Tahmin Değerlendirme Metrikleri

Tahminlerin değerlendirmesi aşamasında en büyük yardımcılarımız performans ölçümlerinde kullanılan hata metriklerimizdir. Bu ölçümler yapılan tahminlerin doğruluğunu değerlendirirler. Performans ölçümlerinde kullanılan metriklerin farklı hesaplama yöntemleri olsalar da tümü zaman serilerindeki gerçek değer ile tahmin edilen değerlerin farklarından çıkan sonuç ile performansları değerlendirilir.

### 3.2.1 RMSE (Root Mean Square Error- Ortalama Karekök Hatası)

Ortalama karekök hatası (RMSE), artıkların (tahmin hataları) standart sapmasıdır. Artıklar, regresyon çizgisi veri noktalarından ne kadar uzakta olduğunun bir ölçüsüdür; RMSE, bu artıkların ne kadar yayıldığına bir ölçüsüdür. Başka bir deyişle, verilerin en uygun çizgi etrafında ne kadar yoğun olduğunu söyler. Ortalama karekök hata, deneysel sonuçları doğrulamak için klimatoloji, tahmin ve regresyon analizinde yaygın olarak kullanılır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (1)$$

Burada, n örnek sayısını,  $y_i$  gerçek değerleri,  $\hat{y}_i$  ise tahmin edilen değerleri göstermektedir (Hyndman and Athanasopoulos, [2019](#)).

### 3.2.2 MAE (Mean Absolute Error- Ortalama Mutlak Hatası)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

MAE yani ortalama mutlak hata iki sürekli deęişken deęerler yani tahmin edilen ve gerçek deęerler arasındaki farkın ölçüsüdür. Ortalama mutlak hata her gerçek deęer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. Ortalama mutlak hata aynı zamanda gerçek veriler ile oluşturulan her veri noktası ile tahmin edilen ve en iyi uyan çizgi arasındaki ortalama yatay mesafedir. Ortalama mutlak hata deęeri dięer metriklere göre daha kolay yorumlanabilir olduęu için regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır. Ortalama mutlak hata yönlerini yani pozitiflik ya da negatiflik durumunu dikkate almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçen, tüm tekil hataların ortalama eşit olarak dağıtan doğrusal bir sonuçtur. Ortalama mutlak hata deęeri 0'dan  $\infty$ 'a kadar deęişebilir. Elde edilen deęerler arasında aykırı deęerler var ve bunları görmezden gelmek istiyorsak MAE dięer metriklere göre daha iyi bir seçenektir. Negatif yönelimli puanlar yani daha düşük deęerlere sahip makine öğrenmesi modelleri daha iyi performans gösterir (Hyndman and Athanasopoulos, [2019](#)).

### 3.2.3 MAPE (Mean Absolute Percentage Error- Ortalama Mutlak Yüzde Hatası)

$$MAPE = \frac{100}{n} \sum_i^n \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (3)$$

Ortalama mutlak yüzde hata zaman serisi modellerinde tahminlerin doğruluğunu ölçmek ve deęerlendirmek için ortalama mutlak yüzde hata sıkça kullanılmaktadır. Toplanan gerçek deęerler arasında sıfır deęeri varsa, sıfır ile bölünme olacağı ve belirsizlik içerdiği için MAPE hesaplanamaz. Verilerin eksik, yanlış ya da düşük olmasından kaynaklanan hata oranı %100 olamaz, ancak tahmin oranının üst bir limiti yoktur. MAPE, kullanılan algoritmaların doğruluğunu karşılaştırmak için kullanıldığında, tahminleri çok düşük olan bir yöntemi sistematik olarak seçmesi nedeniyle önyargılıdır. Bu önyargı sonucu oluşan problemin elde edilen gerçek deęerlerine oranını bulan bir doğruluk ölçütü ile giderilebilir (Hyndman and Athanasopoulos, [2019](#)).

### 3.2.4 MASE (Mean Absolute Scaled Error- Ortalama Mutlak Ölçekli Hatası)

$$MASE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{\frac{n}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|} \quad (4)$$

İstatistiksel deęerlendirmelerde, ortalama mutlak ölçekli hata (MASE) yapılan tahminlerin doğruluğunun bir ölçüsüdür. 2006 yılında Rob J. Hyndman ve Anne B. Koehler tarafından “dięer hata metriklerinde görülen ve sorunsuz tahminlerin

doğruluğunu genel olarak uygulanabilir bir ölçüm” olarak nitelendirmesi önerildi. Ortalama mutlak ölçekli hata diğer hata metriklerinin yaptığı tahmin hatalarını hesaplamak için kullanılan diğer yöntemlerle karşılaştırıldığında pozitif özelliğe sahiptir ve dolayısıyla tahminler karşılaştırılabilir olduklarından doğruluklarını belirlemek için önerilen bir ölçüttür (Hyndman and Athanasopoulos, [2019](#)).



#### 4. ARAŞTIRMA SONUÇLARI ve TARTIŞMA

Bu tezde yapılan araştırmanın amacı hibrit modellerin bağımsız modellerden daha iyi performans sergilediğini ispat etmeye yöneliktir. Burada genel anlamda gerçekleştirilen analizler için kullanılan dört ayrı yaklaşımdan bir tanesi bağımsız modeller yardımıyla yapılırken üç tanesi ise farklı hibrit modellerle yapılmıştır. Bağımsız ve hibrit model karşılaştırmalarının gerçekçi olması için aylık bir zaman serisi olan ve R geliştirme ortamında direkt kullanılabilen ve istatistiksel bilgileri Çizelge 4.1’de verilen Airpassengers tercih edilmiştir.

##### 4.1 Tek Model Kullanılarak Yapılan Tahminler

Birinci yaklaşımdaki amacımız, farklı zaman serilerinin tahmin işlemlerinde kullanılması durumunda, tahmin işleminde kullanılan modellerin ayrı ayrı performanslarını RMSE, MAE, MAPE ve MASE gibi dört ayrı metrik ile ortaya çıkarmak ve bunları karşılaştıracak bir format ile sunmaktır. Birinci yaklaşımda sekiz (8) adet yıllık zaman serisi, üç (3) adet mevsimsel zaman serisi ve onbir (11) adet aylık zaman serisi olmak üzere toplam olarak 22 adet zaman serisi kullanılmıştır. Bu yaklaşımda kullanılan zaman serilerinin içerikleri, kayıt sayısı, frekansı, en küçük değeri, en büyük değeri ve ortalama değeri gibi istatistiksel bilgiler Çizelge 4.1’de verilmiştir. Burada kullanılan zaman serilerinin kayıt uzunlukları 24 ile 528 arasında değişkenlik göstermektedir.

Birinci yaklaşımda 22 ayrı zaman serisi üzerinde ETS, STL, HOLT-WINTERS, ARIMA, THETAF, TBATS, NAİVE, NNTAR, MLP ve ELM gibi 10 tane farklı tahmin modeli kullanılmıştır. Yapılan tahminler sonucunda elde edilen RMSE, MAE, MAPE ve MASE metrik değerleri her bir zaman serisi için MAPE metriğine göre küçükten büyüğe doğru sıralanmış ve Çizelge 4.2’te verilmiştir.

Ayrıca her bir zaman serisinin tahmin işleminde kullanılan 10 adet modelden elde edilen en iyi üç tanesinin küçükten-büyüğe sıralanmış MAPE ortalama metrik değerleri Çizelge 4.3’te verilmiştir.

**Çizelge 4.1** Aylık, yıllık ve mevsimlik zaman serilerine ait istatistiksel bilgiler

Veri kümesi	İçerik	Kayıt sayısı	Türü/ Frekansı	En küçük	En büyük	Ortalama
AirPassengers	Aylık taşınan yolcu sayısı, bin mertebesinde (1949-1960)	144	Aylık/12	104	622	280,30
UKDriverDeaths	İngiltere’de yol kazaları (1969-1984)	192	Aylık/12	1057	2654	1670,31

USAccDeaths	ABD kaza ölümleri (1973-1978)	72	Aylık/12	6892	11317	8788,79
Co2	ABD, Mauna Loa atmosferik aylık co2 ppm değerleri (1959-1997)	468	Aylık/12	323,53	350,26	337,05
Nottem	Nottingham'da ortalama aylık sıcaklıklar (1920–1939)	240	Aylık/12	31,30	57,00	49,04
gas	Avustralya aylık gaz üretimi (1956, 1995)	476	Aylık/12	1646,00	66600,00	21415,27
fdeaths	İngiltere'de astımdan kaynaklanan kadın ölümleri (1974-1979)	72	Aylık/12	330	1141	560,7
mdeaths	İngiltere'de amfizemden kaynaklanan erkek ölümleri (1974-1979)	72	Aylık/12	940	2750	1496
ldeaths	İngiltere'de bronşitten kaynaklanan erkek/kadın ölümleri (1974-1979)	72	Aylık/12	1300	3891	2057
USVSAles	ABD aylık toplam araç satışları, bin adet ( 1976 - 2019)	528	Aylık/12	528	1262.2	670.5
USgas	ABD aylık doğalgaz tüketimi, milyar fit küp ( 2000 - 2019)	238	Aylık/12	1368	3400	2057
BSales	Öncü göstergeli satış verileri	150	Yıllık/1	198,60	263,30	229,98
LakeHuron	Huron Gölü fit cinsinden yıllık ölçümleri (1875–19729)	98	Yıllık/1	576,96	581,86	579,0
Nile	Aswan Nil Nehri yıllık akış ölçümleri (1871-1970)	100	Yıllık/1	456	1370	919,35
WWWusage	Saniyelik internete bağlı kullanıcı sayıları	100	Yıllık/1	83	228	137,08
airmiles	Ticari ABD havayollarında yolcu milleri (1937–1960)	24	Yıllık/1	412	30514	10527,83
Discoveries	Yıllık önemli keşif sayıları (1860-1959)	100	Yıllık/1	0	12	3,1
lynx	Yıllık Kanada vaşak av sayıları (1821–1934)	114	Yıllık/1	39	6991	1538,02
nhtemp	New Haven'da ortalama yıllık sıcaklıklar (1912-1971)	60	Yıllık/1	47,90	54,60	51,16
JohnsonJohnson	Johnson & Johnson üç aylık hisse kazançları (1960-1980)	84	Mevsimlik/4	0,44	16,2	4,8
UKgas	İngiltere üç aylık gaz tüketimi (1960-1986)	108	Mevsimlik/4	84,80	1163,9	337,63
austres	Avustralya'da ikamet eden kişi sayıları (1971-1994)	89	Mevsimlik/4	13067,3	15273,45	1766,15

**Çizelge 4.1** 10 farklı modelin tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE metrik değerlerinin zaman serisi bazında sıralanışı

Sıra no	Zaman serisi	Model adı	RMSE	MAE	MAPE	MASE
1	AirPassengers	MLP	-0,03	2,89	2,09	-0,05

2	AirPassengers	ELM	-0,04	9,71	7,6	-0,1
3	AirPassengers	TBATS	0,46	10,66	7,72	0,24
4	AirPassengers	ETS	1,56	10,74	7,79	0,43
5	AirPassengers	ARIMA	1,34	10,84	7,86	0,42
6	AirPassengers	THETAF	3,03	11	7,86	1,03
7	AirPassengers	STL	-0,16	11,93	8,56	-0,06
8	AirPassengers	NNTAR	0	14,42	11,53	-0,29
9	AirPassengers	HOLT-WINTERS	0,56	33,53	25,61	-0,36
10	AirPassengers	NAÏVE	2,23	33,71	25,86	0,37
11	UKDriverDeaths	MLP	-0,69	46,52	33,48	-0,16
12	UKDriverDeaths	STL	-0,06	102,71	79,85	-0,4
13	UKDriverDeaths	NNTAR	-0,01	112,99	88,81	-0,58
14	UKDriverDeaths	TBATS	-2,61	124,38	100,15	-0,63
15	UKDriverDeaths	ARIMA	-8,1	129,68	100,46	-0,95
16	UKDriverDeaths	THETAF	-3,28	126,59	101,39	-0,65
17	UKDriverDeaths	ETS	-5,57	125,81	102	-0,79
18	UKDriverDeaths	ELM	0,16	134,21	108,11	-0,49
19	UKDriverDeaths	HOLT-WINTERS	0,48	219,57	168,39	-0,88
20	UKDriverDeaths	NAÏVE	0,39	220,75	169,58	-0,81
21	USAccDeaths	MLP	0,62	18,43	8,83	0
22	USAccDeaths	STL	-12,15	211,45	168,38	-0,2
23	USAccDeaths	TBATS	-5,85	253,32	193,87	-0,1
24	USAccDeaths	THETAF	-18,45	254,28	199,19	-0,25
25	USAccDeaths	ARIMA	58,83	285,36	200,95	0,66
26	USAccDeaths	ETS	-2,61	262,69	202,63	-0,08
27	USAccDeaths	NNTAR	0,27	383,98	303,55	-0,21
28	USAccDeaths	ELM	-3,63	408,71	334,8	-0,21
29	USAccDeaths	NAÏVE	3,28	730,15	643,42	-0,31
30	USAccDeaths	HOLT-WINTERS	-38,71	734,8	647,62	-0,8
31	co2	STL	0	0,21	0,16	0
32	co2	MLP	0	0,22	0,18	0
33	co2	ETS	0,04	0,28	0,22	0,01
34	co2	TBATS	0	0,27	0,22	0
35	co2	ELM	0	0,28	0,22	0
36	co2	ARIMA	0,01	0,28	0,23	0
37	co2	THETAF	0,11	0,3	0,24	0,03
38	co2	NNTAR	0	0,52	0,41	0
39	co2	HOLT-WINTERS	0	0,92	0,72	0
40	co2	NAÏVE	0,1	1,21	1,07	0,03
41	Nottem	NNTAR	0	0,94	0,7	-0,08
42	Nottem	MLP	0	0,96	0,73	-0,06
43	Nottem	STL	0	1,87	1,49	-0,15
44	Nottem	ARIMA	-0,05	2,19	1,69	-0,39
45	Nottem	TBATS	0,01	2,23	1,73	-0,22
46	Nottem	ETS	0	2,25	1,74	-0,22
47	Nottem	THETAF	0,07	2,25	1,75	-0,08

48	nottem	ELM	0	2,3	1,85	-0,22
49	nottem	HOLT-WINTERS	-0,03	5,04	3,99	0,56
50	nottem	NAÏVE	-0,01	5,23	4,32	-0,62
51	gas	MLP	-4,73	518,17	349,63	-0,62
52	gas	STL	-1,46	1065,4	590,42	-0,11
53	gas	TBATS	25,45	1455,04	796,11	0,15
54	gas	ETS	42,96	1463,93	796,12	0,3
55	gas	THETAF	197,85	1411,32	818,92	1,21
56	gas	ARIMA	27,72	1579,45	893,45	0,27
57	gas	ELM	-6,16	1668,09	1041,26	-0,92
58	gas	NNTAR	0,52	1874,44	1109,16	-1,14
59	gas	NAÏVE	122,83	2817,27	1726,74	0,25
60	gas	HOLT-WINTERS	-9,28	2969,73	1733,03	0,49
61	fdeaths	MLP	-0,67	24,32	15,7	-0,34
62	fdeaths	STL	0,32	60,51	41,29	-0,68
63	fdeaths	TBATS	-4,48	64,79	43,06	-1,78
64	fdeaths	ARIMA	0,89	68,26	43,5	-0,31
65	fdeaths	ETS	-7,95	65,66	45,28	-2,25
66	fdeaths	THETAF	-7,91	65,7	45,31	-2,25
67	fdeaths	ELM	1,24	73,35	48,69	-2,25
68	fdeaths	NNTAR	0	70,9	49,68	-1,27
69	fdeaths	HOLT-WINTERS	8,19	125,34	92,96	-0,17
70	fdeaths	NAÏVE	-4,6	125,85	94,04	-2,64
71	ldeaths	MLP	0,31	63,99	35,87	-0,09
72	ldeaths	ARIMA	10,67	207,31	126,08	0,05
73	ldeaths	STL	3,33	197,97	139,02	-0,38
74	ldeaths	TBATS	-20,96	213,2	146,18	-1,84
75	ldeaths	ETS	-28,73	223,32	150,3	-1,95
76	ldeaths	THETAF	-32,79	220,96	151,28	-2,18
77	ldeaths	ELM	-1,96	233,54	161,71	-1,82
78	ldeaths	NNTAR	-0,02	259,7	173,43	-1,17
79	ldeaths	HOLT-WINTERS	17,22	407,82	300,13	-0,52
80	ldeaths	NAÏVE	-15,77	410,4	306,14	-2,25
81	mdeaths	MLP	-0,43	31,42	19,67	-0,1
82	mdeaths	ARIMA	6,73	150,3	90,84	-0,19
83	mdeaths	NNTAR	-0,16	141,76	99,34	-0,87
84	mdeaths	STL	3,01	142,3	100,73	-0,34
85	mdeaths	ETS	-13,39	155,36	109,03	-1,32
86	mdeaths	THETAF	-23,71	161,37	111,24	-2,17
87	mdeaths	TBATS	-19,34	160,83	114,79	-2,14
88	mdeaths	ELM	1,92	189,49	138,65	-2,16
89	mdeaths	HOLT-WINTERS	8,82	289,66	213,85	-0,76
90	mdeaths	NAÏVE	-11,16	291,7	217,42	-2,21
91	USVSales	NNTAR	0,16	11,27	7,81	-0,03
92	USVSales	STL	0,16	65,49	48,1	-0,33
93	USVSales	MLP	-0,26	82,82	62,22	-0,18

94	USVSales	ARIMA	2,86	88,52	65,46	-0,19
95	USVSales	ETS	0,73	91,05	69,5	-0,34
96	USVSales	TBATS	2,36	96,16	72,78	-0,28
97	USVSales	THETAF	2,61	95,45	73,15	-0,32
98	USVSales	ELM	0,05	106,9	79,34	-0,18
99	USVSales	HOLT-WINTERS	0,03	150,28	120,53	-1,16
100	USVSales	NAÏVE	1,28	169,97	134,34	-0,81
101	USgas	MLP	-1,24	41,75	29,54	-0,13
102	USgas	STL	0,08	82,46	63,09	-0,14
103	USgas	TBATS	11,35	97,67	72,49	0,34
104	USgas	ARIMA	5,95	98,67	74,38	0,11
105	USgas	ELM	0	102,12	74,46	-0,21
106	USgas	THETAF	6,08	102,96	76,33	0,14
107	USgas	ETS	3,99	105,08	79,41	0,12
108	USgas	NNTAR	-0,13	124,51	97,08	-0,35
109	USgas	HOLT-WINTERS	0,73	287,59	230,11	-0,83
110	USgas	NAÏVE	-0,16	288	230,46	-0,88
111	BJsales	MLP	0	1,08	0,83	0
112	BJsales	ETS	0,14	1,32	1,04	0,06
113	BJsales	ARIMA	0,14	1,32	1,04	0,06
114	BJsales	HOLT-WINTERS	0,01	1,35	1,06	0
115	BJsales	TBATS	0,16	1,35	1,06	0,07
116	BJsales	NNTAR	0	1,41	1,08	0
117	BJsales	ELM	0	1,45	1,13	0
118	BJsales	THETAF	0,41	1,49	1,15	0,17
119	BJsales	NAÏVE	0,42	1,49	1,16	0,18
120	BJsales	STL	NA	NA	NA	NA
121	LakeHuron	NNTAR	0	0,63	0,5	0
122	LakeHuron	MLP	0	0,63	0,5	0
123	LakeHuron	TBATS	0	0,73	0,57	0
124	LakeHuron	ELM	0	0,71	0,57	0
125	LakeHuron	ETS	0	0,74	0,58	0
126	LakeHuron	HOLT-WINTERS	0	0,74	0,58	0
127	LakeHuron	ARIMA	0	0,74	0,58	0
128	LakeHuron	THETAF	0	0,74	0,58	0
129	LakeHuron	NAÏVE	0	0,74	0,58	0
130	LakeHuron	STL	NA	NA	NA	NA
131	Nile	MLP	-0,73	129,18	102,85	-2,33
132	Nile	NNTAR	0	132,84	105,31	-2,36
133	Nile	ARIMA	-16,06	139,89	110	-4
134	Nile	ETS	-16,43	143,58	111,92	-4,22
135	Nile	HOLT-WINTERS	0,14	142,16	112,16	-2,24
136	Nile	THETAF	-12,43	142,78	112,24	-3,65
137	Nile	TBATS	-11,15	142,86	112,88	-3,53
138	Nile	ELM	0,08	151,26	122,66	-3,07
139	Nile	NAÏVE	-3,83	167,32	133,25	-2,22

140	Nile	STL	NA	NA	NA	NA
141	WWUsage	MLP	-0,01	2,78	2,2	0,09
142	WWUsage	ARIMA	0,3	3,11	2,4	0,28
143	WWUsage	NNTAR	0	2,93	2,4	-0,05
144	WWUsage	ELM	0	3,29	2,58	0,01
145	WWUsage	TBATS	0,21	3,46	2,62	0,26
146	WWUsage	ETS	0,22	3,4	2,76	0,26
147	WWUsage	HOLT-WINTERS	-0,05	3,63	2,99	0,1
148	WWUsage	THETAF	1,32	5,77	4,48	0,82
149	WWUsage	NAÏVE	1,33	5,8	4,52	0,82
150	WWUsage	STL	NA	NA	NA	NA
151	airmiles	NNTAR	0,27	846,53	564,8	-4,71
152	airmiles	TBATS	195,19	1006,93	742,71	3,71
153	airmiles	ARIMA	268,72	1039,34	758,53	4,77
154	airmiles	HOLT-WINTERS	218,61	1034,9	811,51	0,07
155	airmiles	ETS	218,76	1034,9	811,57	0,07
156	airmiles	MLP	-2,82	1008,84	934,72	-8,62
157	airmiles	ELM	0	1192,37	1058	-13,14
158	airmiles	THETAF	1254,2	1731,73	1265,19	15,49
159	airmiles	NAÏVE	1308,78	1768,86	1319,91	16,2
160	airmiles	STL	NA	NA	NA	NA
161	discoveries	MLP	0	1,6	1,21	-Inf
162	discoveries	NNTAR	0	1,85	1,46	-Inf
163	discoveries	HOLT-WINTERS	0	2,13	1,66	-Inf
164	discoveries	ETS	-0,08	2,13	1,67	-Inf
165	discoveries	ARIMA	-0,12	2,13	1,67	-Inf
166	discoveries	THETAF	-0,08	2,13	1,67	-Inf
167	discoveries	TBATS	-0,09	2,13	1,67	-Inf
168	discoveries	ELM	0	2,24	1,67	-Inf
169	discoveries	NAÏVE	-0,05	2,69	2,01	-Inf
170	discoveries	STL	NA	NA	NA	NA
171	lynx	NNTAR	-1,59	286,15	213,33	-36,63
172	lynx	MLP	-6,9	525,97	340	-29,05
173	lynx	TBATS	52,88	827,16	496,32	-21,21
174	lynx	ARIMA	-1,6	853,54	610,11	-63,9
175	lynx	ELM	0,08	899,44	653,75	-121,03
176	lynx	THETAF	27,24	1182,14	823,79	-45,33
177	lynx	NAÏVE	27,67	1187,31	830,85	-45,65
178	lynx	HOLT-WINTERS	-133,25	1215,33	841,76	-79,91
179	lynx	ETS	8,97	1198,45	842,06	-52,12
180	lynx	STL	NA	NA	NA	NA
181	nhtemp	NNTAR	0	0,99	0,79	-0,03
182	nhtemp	MLP	0	1,08	0,86	-0,04
183	nhtemp	ETS	0,14	1,12	0,89	0,24
184	nhtemp	HOLT-WINTERS	0	1,11	0,89	-0,04
185	nhtemp	ARIMA	0,12	1,12	0,89	0,2

186	Nhtemp	THETAF	0,14	1,12	0,89	0,24
187	Nhtemp	TBATS	0,13	1,12	0,89	0,21
188	Nhtemp	ELM	0	1,25	0,96	-0,06
189	Nhtemp	NAİVE	0,05	1,45	1,19	0,06
190	Nhtemp	STL	NA	NA	NA	NA
191	JohnsonJohnson	STL	0	0,16	0,1	-0,59
192	JohnsonJohnson	MLP	0	0,26	0,18	-0,9
193	JohnsonJohnson	NNTAR	0	0,35	0,23	-0,7
194	JohnsonJohnson	ARIMA	0,07	0,4	0,26	2,13
195	JohnsonJohnson	TBATS	0	0,43	0,28	0,35
196	JohnsonJohnson	ETS	0,06	0,47	0,29	1,4
197	JohnsonJohnson	ELM	0	0,5	0,34	-0,74
198	JohnsonJohnson	THETAF	0,27	0,79	0,44	5,15
199	JohnsonJohnson	HOLT-WINTERS	0,01	0,98	0,54	0,11
200	JohnsonJohnson	NAİVE	0,13	1,42	0,78	1,07
201	UKgas	STL	-0,16	13,49	9,42	-0,36
202	UKgas	MLP	-0,02	20,86	14,45	-0,44
203	UKgas	NNTAR	-0,01	31,04	21,43	-1,07
204	UKgas	ETS	4,7	32,16	21,63	0,32
205	UKgas	TBATS	4,97	33,53	22,04	0,08
206	UKgas	ARIMA	4,71	34,17	22,73	0,13
207	UKgas	ELM	0,06	39,85	27,17	-1,81
208	UKgas	THETAF	28,19	81,22	56,06	3,15
209	UKgas	HOLT-WINTERS	2,8	165,97	113,38	-15,01
210	UKgas	NAİVE	5,81	231,27	175,63	-13,91
211	Austres	MLP	-0,01	5,65	3,78	0
212	Austres	STL	0,28	5,56	4,29	0
213	Austres	TBATS	-0,65	8,83	6,19	0
214	Austres	ETS	1,7	9,24	6,6	0,01
215	Austres	ARIMA	-0,59	9,95	7,08	0
216	Austres	NNTAR	0,02	9,19	7,09	0
217	Austres	HOLT-WINTERS	-0,89	10,18	7,5	0
218	Austres	ELM	0	10,12	7,71	0
219	Austres	THETAF	51,62	53,27	51,62	0,33
220	Austres	NAİVE	52,2	53,71	52,2	0,34

**Çizelge 4.2** 22 adet zaman serisi için kullanılan 10 ayrı modelden en iyi üç tanesinin MAPE ortalama değerlerinin MAPE bazından küçükten büyüğe doğru sıralanışı

Zaman serisi	Frekansı	İlk üç model için MAPE ortalama değeri
JohnsonJohnson	4	0,17
Co2	12	0,18
LakeHuron	1	0,53
Nhtemp	1	0,84
Nottem	12	0,97
BJsales	1	0,97

Discoveries	1	1,44
WWWusage	1	2,33
austres	4	4,75
AirPassengers	12	5,8
UKgas	4	15,1
fdeaths	12	33,35
USVSales	12	39,37
USgas	12	55,04
UKDriverDeaths	12	67,38
mdeaths	12	69,95
ldeaths	12	100,32
Nile	1	106,05
USAccDeaths	12	123,69
lynx	1	349,88
gas	12	578,72
airmiles	1	688,68

## 4.2 Hibrit Model Kullanılarak Yapılan Tahminler

R programlama dili geliştirme ortamına dahil edilerek kullanılabilen hybridmodel paketi, **forecast** paketinde yer alan modelleri tek tek kullanarak bileşik modeller oluşturmaktadır. En fazla altı bileşenli olabilen bileşik modeller auto.arima (a), ets (e), thetam (f), nnetar (n), stlm (s) ve tbats (t) modellerinden oluşmaktadır.

Hibrid modelin avantajları olduğu gibi dezavantajları da bulunmaktadır. Girdi serilerinin özellikleri, belirli model ve parametre türleri için sorunlara neden olabilir. Örneğin, STLM modelleri, girdi serilerinin mevsimlik olmasını gerektirir; ayrıca, ayırıştırmanın başarılı olması için verilerin en az iki mevsimlik veri içermesi gerekir. Durum böyle değilse, yani zaman serisi mevsimsellik içermiyorsa, hybridModel() STLM modelini etkisiz bırakacak ve böylece bir hata oluşmayacaktır. Buna ilaveten ets modeli de mevsimsel periyodu 24'ten uzun olan bir seriyi iyi işlemez ve mevsimselliği göz ardı eder. Bu durumda hybridModel(), ets modelini de topluluktan çıkaracaktır.

### 4.2.1 Hibrit Model Kullanılarak Farklı Katkıya Sahip Yapılan Tahminler

İkinci yaklaşımda hybridModel kullanılarak birden fazla modelin tahmin işleminde “değişken ağırlıklı” olarak katkı sunmasına imkân sağlandı. HybridModel içinde kullanılan önemli parametrelerden üçü sırasıyla models, weights ve errorMethod olarak isimlendirilmiştir. Models parametresine; auto.arima (a), ets (e), thetam (f), nnetar

(n), stlm (s) ve tbats (t) modellerinden en az iki tanesi atanması gerekmektedir. Burada weights parametresi için “insample.errors” değeri atanırken, errorMethod parametresi için de “MASE” değeri atanarak kullanılmıştır. Model parametresine ise sırasıyla ikili, üçlü, dördü, beşli ve altılı model ataması yapılarak kullanılmıştır. Bunun farklı değerlerinin doğru hesaplanması için kombinasyon denkleminde faydalanılmıştır.

$$C(n, r) = \binom{n}{r} = \binom{n}{n-r} = \frac{P(n,r)}{r!} = \frac{n!}{r!(n-r)!} \quad (1)$$

Burada n parametresi, hibrit modelde bir arada kullanılacak model sayısını ifade ederken, r parametresi birlikte kullanılan çoklu durumları ifade etmektedir. Bu durumda C(6,2), C(6,3), C(6,4), C(6,5) ve C(6,6) için sırasıyla 15, 20, 15, 6 ve 1 tahmin analizi yapılmıştır. Tahmin işleminde birden fazla modelin yer aldığı ve HybridModel yardımıyla yapılan değişken ağırlıklı ikili, üçlü, dördü, beşli ve altılı analizlere ait metrik değerleri sırasıyla Çizelge 4.4-Çizelge 4.8 aralığında verilmiştir.

**Çizelge 4.4** HybridModel ile yapılan değişken ağırlıklı ikili model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	İkili model	RMSE	MAE	MAPE	MASE
1	AirPassengers	fn	17,04	13,8	2,87	0,45
2	AirPassengers	nt	16,94	13,4	2,92	0,44
3	AirPassengers	ae	19,27	14	3	0,45
4	AirPassengers	an	17,87	14,1	3,1	0,46
5	AirPassengers	af	19,89	14,4	3,23	0,47
6	AirPassengers	en	19,81	16	3,26	0,52
7	AirPassengers	ft	21,92	15,7	3,3	0,51
8	AirPassengers	et	23,08	16,7	3,44	0,54
9	AirPassengers	at	21,82	15,3	3,46	0,5
10	AirPassengers	as	21,66	17,2	3,62	0,56
11	AirPassengers	ns	24,17	20	3,95	0,65
12	AirPassengers	st	25,5	20	4,04	0,65
13	AirPassengers	es	29,96	23,6	4,61	0,77
14	AirPassengers	ef	28	23,5	4,78	0,77
15	AirPassengers	fs	33,06	25,7	4,96	0,84

**Çizelge 4.5** HybridModel ile yapılan değişken ağırlıklı üçlü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Üçlü model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aen	16,85	13,1	2,81	0,42
2	AirPassengers	afn	16,45	13	2,83	0,42
3	AirPassengers	fnt	17,02	13,7	2,93	0,44

4	AirPassengers	ant	18,37	13,3	2,96	0,43
5	AirPassengers	aef	19,75	14,4	3,03	0,47
6	AirPassengers	ent	19,12	14,8	3,07	0,48
7	AirPassengers	aet	19,97	14,3	3,08	0,46
8	AirPassengers	aft	20,42	13,8	3,1	0,45
9	AirPassengers	ans	19,05	15,2	3,19	0,49
10	AirPassengers	ast	21,13	16,3	3,47	0,53
11	AirPassengers	nst	21,49	17,4	3,55	0,57
12	AirPassengers	efn	21,52	17,7	3,58	0,57
13	AirPassengers	aes	22,38	17,7	3,61	0,58
14	AirPassengers	eft	23,67	17,6	3,61	0,57
15	AirPassengers	afs	21,88	17,6	3,64	0,57
16	AirPassengers	ens	24,6	19,7	3,89	0,64
17	AirPassengers	fns	24,51	19,9	3,92	0,65
18	AirPassengers	est	25,74	19,8	3,95	0,64
19	AirPassengers	fst	25,81	20,2	4,04	0,66
20	AirPassengers	efs	29,97	23,9	4,69	0,78

**Çizelge 4.6** HybridModel ile yapılan değişken ağırlıklı dördü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Dördü model	RMSE	MAE	MAPE	MASE
1	AirPassengers	afnt	17,56	12,9	2,85	0,42
2	AirPassengers	aefn	17,63	13,7	2,9	0,44
3	AirPassengers	aent	17,96	13,6	2,93	0,44
4	AirPassengers	aeft	20,12	14,5	3,1	0,47
5	AirPassengers	efnt	20,2	15,3	3,14	0,5
6	AirPassengers	anst	19,05	15,1	3,2	0,49
7	AirPassengers	afns	19,21	15,5	3,23	0,5
8	AirPassengers	aens	20,05	16,2	3,33	0,53
9	AirPassengers	aest	21,67	16,6	3,43	0,54
10	AirPassengers	afst	21,25	16,4	3,45	0,53
11	AirPassengers	fnst	21,67	17,6	3,58	0,57
12	AirPassengers	enst	22,39	17,9	3,6	0,58
13	AirPassengers	aefs	22,77	17,9	3,64	0,58
14	AirPassengers	efns	24,72	19,9	3,93	0,65
15	AirPassengers	efst	26,03	19,9	3,96	0,65

**Çizelge 4.7** HybridModel ile yapılan değişken ağırlıklı beşli model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Beşli model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aefnt	18,32	14	2,99	0,46
2	AirPassengers	afnst	19,3	15,3	3,22	0,5

3	AirPassengers	aenst	19,93	15,6	3,25	0,51
4	AirPassengers	aefns	20,49	16,6	3,38	0,54
5	AirPassengers	aefst	21,95	16,8	3,46	0,55
6	AirPassengers	efnst	22,84	18	3,62	0,59

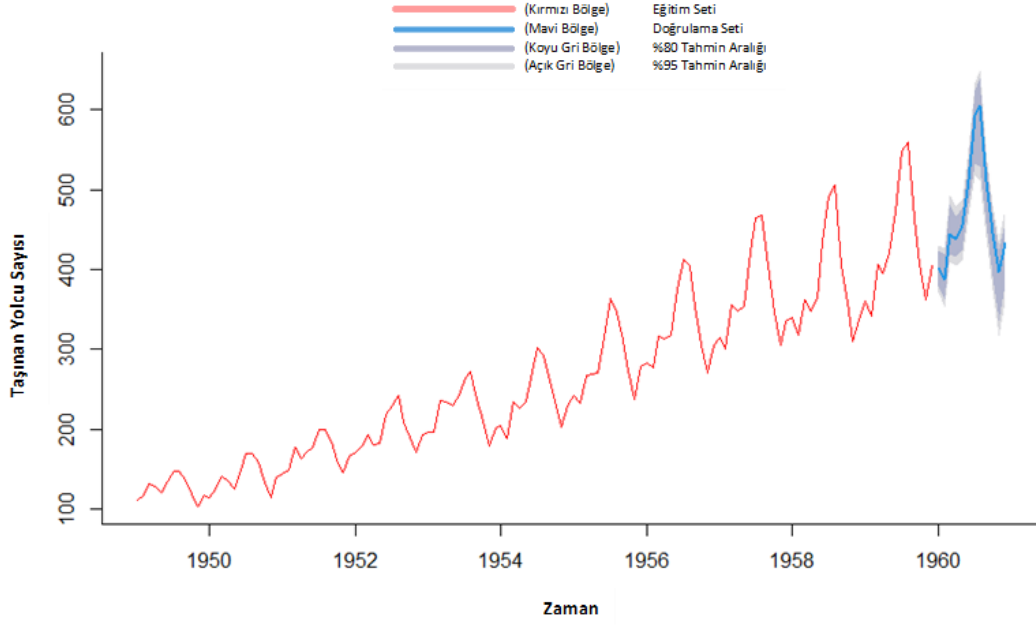
**Çizelge 4.8** HybridModel ile yapılan değişken ağırlıklı altılı model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Altılı model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aefnst	20,15	15,8	3,28	0,52


İkili, üçlü, dördü, beşli ve altılı modellere ait MAPE metriğine göre en iyi tahminleri yapan çoklu modellere ait grafikler sırasıyla Şekil 4.2.1.1, Şekil 4.2.1.2, Şekil 4.2.1.3, Şekil 4.2.1.4 ve Şekil 4.2.1.5'te grafiksel olarak verilmiştir. Bir tahmin elde edildiğinde, rastgele değişkenin alabileceği olası değerler aralığının ortası tahmin edilmektedir. Genellikle, bir tahmine, rastgele değişkenin nispeten yüksek olasılıkla alabileceği bir dizi değer veren bir tahmin aralığı eşlik eder. Örneğin, %95'lik bir tahmin aralığı, %95 olasılıkla gerçek gelecek değeri içermesi gereken bir değer aralığı içerir.

Grafiklerdeki mavi çizgiler 1949-1960 yılları arasındaki verilerden meydana gelen AirPassengers verisetinin 1960 yılına ait 12-aylık tahmin ortalamalarını göstermektedir. Tahminlerin, tarihsel verilerde görülen mevsimsel kalıbı nasıl yakaladığına ve sonraki yıl için nasıl kopyaladığına dikkat edilmelidir. Aynı grafiklerdeki ADF koyu gölgeli bölgeler %80 tahmin aralığı göstermektedir. Yani, gelecekteki her değer %80 olasılıkla koyu gölgeli bölgelerde olması beklenir. Buna karşın açık gölgeli bölgeler ise %95 tahmin aralığı göstermektedir.


Bu tahmin aralıkları, tahminlerdeki belirsizliği göstermenin faydalı bir yoludur. Bu durumda tahminlerin doğru olması beklenir ve bu nedenle tahmin aralıkları oldukça dardır.




Şekil 4.1 Hybridmodel kullanılarak ikili grupta en iyi tahmini yapan “fn” modeline ait tahmin grafiği




Şekil 4.2 Hybridmodel kullanılarak üçlü grupta en iyi tahmini yapan “aen” modeline ait tahmin grafiği



Şekil 4.3 Hybridmodel kullanılarak dördü grupta en iyi tahmini yapan “afnt” modeline ait tahmin grafiği



Şekil 4.4 Hybridmodel kullanılarak beşli grupta en iyi tahmini yapan “aefnt” modeline ait tahmin grafiği



Şekil 4.5 Hybridmodel kullanılarak altılı grupta en iyi tahmini yapan “aefnst” modeline ait tahmin grafiği

#### 4.2.2 Hibrit Model Kullanılarak Eşit Katkıya Sahip Yapılan Tahminler

Üçüncü yaklaşımda hybridModel kullanılarak birden fazla modelin tahmin işleminde “eşit ağırlıklı” olarak katkı sunmasına imkân sağlandı. Bu yaklaşımda öncekinden farklı olarak weights parametresi için “equal” değeri atanırken, errorMethod parametresi için de “MASE” değeri atanarak kullanılmıştır. Model parametresine ise ikinci yaklaşımda olduğu gibi sırasıyla ikili, üçlü, dördü, beşli ve altılı model ataması yapılarak kullanılmıştır. Bu işlem için Denklem (1)’de verilen kombinasyon denkleminde faydalanılmıştır.

HybridModel yardımıyla yapılan eşit ağırlıklı ikili, üçlü, dördü, beşli ve altılı analizlere ait metrik değerleri sırasıyla Çizelge 4.9-Çizelge 4.13 aralığında verilmiştir.

Çizelge 4.9 HybridModel ile yapılan eşit ağırlıklı ikili model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Eşit ağırlıklı ikili model	RMSE	MAE	MAPE	MASE
1	AirPassengers	en	17,99	14,08	2,89	0,46
2	AirPassengers	nt	16,24	13,36	2,89	0,43
3	AirPassengers	ae	19,18	13,91	2,99	0,45
4	AirPassengers	af	19,35	14,27	3,01	0,46
5	AirPassengers	an	17,06	13,88	3,01	0,45
6	AirPassengers	fn	19,76	15,85	3,2	0,52

7	AirPassengers	et	22,73	16,29	3,37	0,53
8	AirPassengers	at	21,74	15	3,41	0,49
9	AirPassengers	ft	23,51	17,29	3,54	0,56
10	AirPassengers	ns	21,12	17,64	3,55	0,57
11	AirPassengers	as	21,59	17,14	3,6	0,56
12	AirPassengers	st	24,88	19,4	3,93	0,63
13	AirPassengers	es	30,05	23,57	4,61	0,77
14	AirPassengers	fs	31,8	25,34	4,95	0,83
15	AirPassengers	ef	28,97	24,56	4,99	0,8

**Çizelge 4.10** HybridModel ile yapılan eşit ağırlıklı üçlü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Eşit ağırlıklı üçlü model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aen	16,32	12,82	2,76	0,42
2	AirPassengers	afn	16,51	13,14	2,79	0,43
3	AirPassengers	ant	17,48	13,13	2,9	0,43
4	AirPassengers	ent	18,12	14,43	3,02	0,47
5	AirPassengers	fnt	18,68	14,66	3,03	0,48
6	AirPassengers	ans	17,89	14,54	3,08	0,47
7	AirPassengers	aet	20,04	14,27	3,09	0,46
8	AirPassengers	aft	19,97	14,51	3,1	0,47
9	AirPassengers	aef	21,24	15,76	3,23	0,51
10	AirPassengers	nst	19,77	16,22	3,34	0,53
11	AirPassengers	ast	21,07	16,2	3,45	0,53
12	AirPassengers	aes	22,25	17,6	3,6	0,57
13	AirPassengers	afs	22,91	18,16	3,67	0,59
14	AirPassengers	efn	22	18,12	3,67	0,59
15	AirPassengers	ens	22,91	18,56	3,69	0,6
16	AirPassengers	eft	24,61	18,73	3,82	0,61
17	AirPassengers	fns	24,39	19,45	3,83	0,63
18	AirPassengers	est	25,26	19,39	3,89	0,63
19	AirPassengers	fst	26,09	19,98	3,97	0,65
20	AirPassengers	efs	30,1	24,49	4,85	0,8

**Çizelge 4.11** HybridModel ile yapılan eşit ağırlıklı dördü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Eşit ağırlıklı dördü model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aent	17,1	13,1	2,85	0,43
2	AirPassengers	afnt	17,25	13,44	2,88	0,44
3	AirPassengers	aefn	18,39	14,27	2,96	0,46
4	AirPassengers	anst	18,25	14,64	3,12	0,48
5	AirPassengers	aeft	20,88	15,14	3,16	0,49
6	AirPassengers	efnt	20,3	15,62	3,19	0,51
7	AirPassengers	aens	19,29	15,67	3,23	0,51
8	AirPassengers	afns	19,14	15,71	3,23	0,51
9	AirPassengers	aest	21,52	16,31	3,4	0,53
10	AirPassengers	enst	21,03	16,91	3,44	0,55
11	AirPassengers	afst	21,84	16,73	3,45	0,54

12	AirPassengers	fnst	21,57	17,33	3,5	0,56
13	AirPassengers	aefs	23,69	18,44	3,7	0,6
14	AirPassengers	efns	24,37	19,71	3,91	0,64
15	AirPassengers	efst	26,29	20,18	4,02	0,66

**Çizelge 4.12** HybridModel ile yapılan eşit ağırlıklı beşli model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Eşit ağırlıklı beşli model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aefnt	18,42	14,27	3	0,46
2	AirPassengers	aenst	19,2	15,27	3,19	0,5
3	AirPassengers	afnst	19,28	15,37	3,19	0,5
4	AirPassengers	aefns	20,74	16,65	3,38	0,54
5	AirPassengers	aefst	22,55	17,22	3,51	0,56
6	AirPassengers	efnst	22,66	17,84	3,58	0,58

**Çizelge 4.13** HybridModel ile yapılan eşit ağırlıklı altılı model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Eşit ağırlıklı altılı model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aefnst	19,99	15,83	3,26	0,52

### 4.2.3 Hibrit Model Yardımıyla Çapraz-Doğrulama Kullanılarak Yapılan Tahminler

Dördüncü yaklaşımda öncekinden farklı olarak weights parametresi için “cv.errors” değeri atanırken, errorMethod parametresi için de “RMSE” değeri atanarak kullanılmıştır. Model parametresine ise ikinci ve üçüncü yaklaşımda olduğu gibi sırasıyla ikili, üçlü, dördü, beşli ve altılı model ataması yapılarak kullanılmıştır. Bu işlem için Denklem (1)’de verilen kombinasyon denkleminde faydalanılmıştır.

HybridModel yardımıyla yapılan çapraz-doğrulama (cv) ikili, üçlü, dördü, beşli ve altılı analizlere ait metrik değerleri sırasıyla Çizelge 4.14-Çizelge 4.18 aralığında verilmiştir.

**Çizelge 4.14** HybridModel ile yapılan çapraz-doğrulama ikili model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	İkili model	RMSE	MAE	MAPE	MASE
1	AirPassengers	nt	16,19	13,51	2,91	0,44
2	AirPassengers	an	16,63	13,56	2,94	0,44
3	AirPassengers	en	18,53	14,5	2,96	0,47

4	AirPassengers	ae	19,48	14,17	3,02	0,46
5	AirPassengers	af	19,92	14,69	3,06	0,48
6	AirPassengers	fn	20,23	16,42	3,31	0,53
7	AirPassengers	at	21,72	14,93	3,39	0,49
8	AirPassengers	et	22,96	16,54	3,42	0,54
9	AirPassengers	ft	23,9	17,82	3,64	0,58
10	AirPassengers	ns	22,93	18,85	3,75	0,61
11	AirPassengers	as	23,11	18,82	3,87	0,61
12	AirPassengers	st	26,06	20,54	4,12	0,67
13	AirPassengers	es	30,35	23,68	4,62	0,77
14	AirPassengers	fs	31,96	25,25	4,91	0,82
15	AirPassengers	ef	28,98	24,57	4,99	0,8

**Çizelge 4.15** HybridModel ile yapılan çapraz-doğrulama üçlü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Üçlü model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aen	16,52	13,14	2,8	0,43
2	AirPassengers	afn	16,87	13,54	2,85	0,44
3	AirPassengers	ant	17,32	13,24	2,91	0,43
4	AirPassengers	ent	18,35	14,57	3,03	0,47
5	AirPassengers	fnt	19,16	14,96	3,07	0,49
6	AirPassengers	aet	20,13	14,43	3,1	0,47
7	AirPassengers	aft	20,18	14,7	3,11	0,48
8	AirPassengers	ans	19,02	15,65	3,25	0,51
9	AirPassengers	aef	22	16,41	3,34	0,53
10	AirPassengers	nst	20,11	16,75	3,43	0,55
11	AirPassengers	ast	21,86	16,97	3,56	0,55
12	AirPassengers	efn	22,62	18,61	3,76	0,61
13	AirPassengers	aes	23,59	18,74	3,78	0,61
14	AirPassengers	ens	23,64	19,14	3,79	0,62
15	AirPassengers	afs	24,38	19,33	3,87	0,63
16	AirPassengers	fns	24,88	19,98	3,93	0,65
17	AirPassengers	eft	24,97	19,31	3,94	0,63
18	AirPassengers	est	26,07	20,15	4,02	0,66
19	AirPassengers	fst	26,97	20,74	4,1	0,68
20	AirPassengers	efs	30,27	24,49	4,83	0,8

**Çizelge 4.16** HybridModel ile yapılan çapraz-doğrulama dördü model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Dördü model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aent	17,36	13,51	2,9	0,44
2	AirPassengers	afnt	17,28	13,59	2,9	0,44
3	AirPassengers	aefn	18,44	14,36	2,97	0,47
4	AirPassengers	aeft	21,35	15,4	3,19	0,5

5	AirPassengers	anst	18,81	15,26	3,21	0,5
6	AirPassengers	efnt	20,81	16,05	3,27	0,52
7	AirPassengers	aens	19,92	16,39	3,36	0,53
8	AirPassengers	afns	20,62	16,89	3,43	0,55
9	AirPassengers	enst	21,72	17,52	3,54	0,57
10	AirPassengers	aest	22,42	17,33	3,56	0,56
11	AirPassengers	afst	22,87	17,77	3,62	0,58
12	AirPassengers	fnst	22,74	18,19	3,64	0,59
13	AirPassengers	aefs	24,85	19,34	3,85	0,63
14	AirPassengers	efns	24,98	20,14	3,98	0,66
15	AirPassengers	efst	26,94	20,78	4,12	0,68

**Çizelge 4.17** HybridModel ile yapılan çapraz-doğrulama beşli model tahminlerine ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Beşli model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aefnt	18,85	14,49	3,02	0,47
2	AirPassengers	aenst	19,47	15,65	3,25	0,51
3	AirPassengers	afnst	20,02	16,09	3,31	0,52
4	AirPassengers	aefns	21,68	17,36	3,49	0,57
5	AirPassengers	efnst	22,93	18,13	3,62	0,59
6	AirPassengers	aefst	23,49	18,1	3,66	0,59

**Çizelge 4.18** HybridModel ile yapılan çapraz-doğrulama altılı tahminlere ait RMSE, MAE, MAPE ve MASE değerlerinin MAPE değerine göre küçükten büyüğe doğru sıralanmış hali

No	Veri Seti	Altılı model	RMSE	MAE	MAPE	MASE
1	AirPassengers	aefnst	21,08	16,71	3,4	0,54

## 5. SONUÇLAR ve ÖNERİLER

Yapılan analizlerin sonuçları; tek model kullanılarak bağımsız olarak yapılan, hibrit model kullanılarak farklı katkıya sahip yapılan, hibrit model kullanılarak eşit katkıya sahip yapılan ve hibrit model yardımıyla çapraz-doğrulama kullanılarak yapılan tahmin sonuçları biçiminde değerlendirilmiştir.

### 5.1 Sonuçlar

#### 5.1.1 Tek Model Kullanılarak Yapılan Tahmin Sonuçları

Çizelge 4.2'de verilen ve ETS, STL, HOLT-WINTERS, ARIMA, THETAF, TBATS, NAİVE, NNTAR, MLP ve ELM gibi 10 ayrı modelin AirPassengers aylık zaman serisi üzerinde kullanıldığı analiz işleminde MAPE metriğine göre en iyi sonuçlara sırasıyla MLP, ELM ve TBATS modelleri yardımıyla ulaşılmıştır. AirPassengers zaman serisi için kullanılan 10 modelin MAPE ortalaması, yani hata tahmin ortalaması 11.25% tir. Diğer bir ifadeyle modellerin ortalama doğruluğu 88,75% tir.

Aynı çizelgede UKDriverDeaths aylık zaman serisi kullanıldığı durumda ilk üç model MLP, STL ve NNTAR olduğu görülmektedir. Devamında kullanılan USAccDeaths aylık zaman serisi için ilk üç model MLP, STL ve TBATS olarak sıralanmaktadır. CO2 için ilk üç model STL, MLP ve ETS iken notem için bu sıralama NNTAR, MLP ve STL olarak değişmektedir. Gas ve fdeaths aylık zaman serileri için ilk üçlü MLP, STL ve TBATS iken ldeaths için MLP, ARIMA ve STL iken mdeaths için bu sıralama MLP, ARIMA, NNETAR olmaktadır. USVSales aylık zaman serisi için ilk üçlü NNETAR, STL ve MLP iken USgas için bu sıralama MLP, STL ve TBATS olarak değişmektedir. BJsales yıllık zaman serisi için ilk üçlü MLP, ETS ve ARIMA iken LakeHuron için bu sıralama NNTAR, MLP, TBATS olmaktadır. Nile için ilk üçlü MLP, NNTR ve ARIMA iken WWWusage için ilk üçlü MLP, ARIMA ve NNTAR olmaktadır. Airmiles yıllık zaman serisi için ilk üçlü NNTAR, TBATS ve ARIMA iken discoveries yıllık zaman serisi için ilk üçlü MLP, NNTAR ve HOLT-WINTERS olmaktadır.

lynx yıllık zaman serisi için ilk üçlü NNTAR, MLP ve TBATS iken nhtemp için bu sıralama NNTAR, MLP ve ETS olmaktadır. JohnsonJohnson ve UKgas mevsimlik zaman serileri için ilk üçlü STL, MLP ve NNTAR iken austres mevsimlik zaman serisi için bu sıralama MLP, STL ve TBATS olarak değişmektedir. MLP modeli 22 adet zaman serisinin tahmin işlemi sonucunda elde edilen MAPE metriğine göre 14 tanesinde ilk sıraya yerleşmiştir. Bunları AirPassengers, UKDriverDeaths, USAccDeaths, gas, fdeaths,

Ideaths, mdeaths, USgas, BJsales, Nile, WWWusage, discoveries, lynx ve austres olarak sıralayabiliriz. MLP modeli ayrıca 6 tane zaman serisi tahmin işleminde ikinci sıraya ve 1 tanesinde ise üçüncü sıraya yerleşmiştir. Dolayısıyla 22 adet tahmin işleminin 21'i için ilk üçte yer alarak en iyi tahmin işleminde rol oynamıştır. İkinci olarak ilk üçte en çok yer alan NNTAR, STL, TBATS ve ARIMA modelleri sırasıyla 13, 12, 9 ve 6 defa ilk üçte yer almışlardır.

Her bir zaman serisi üzerinde uygulanan modellerin en iyi üç tanesinin tahminlerinin MAPE metrik ortalaması ile Çizelge 4.3 elde edilmiştir. Bu çizelgede en iyi tahmin yapan MLP, NNTAR ve STL modelleri JohnsonJohnson zaman serisi için büyük rol oynamışlardır.

### 5.1.2 Hibrit Model Kullanılarak Farklı Katkıya Sahip Yapılan Tahmin Sonuçları

Hibrit modellerin performansları ölçülürken 144 kayıttan oluşan aylık AirPassengers zaman serisi kullanılmıştır. AirPassengers zaman serisinin baştan 132 aylık verisi eğitim işlemi için ayrılırken geriye kalan 12 aylık veri ise test işlemi için kullanılmıştır.

Çizelge 4.4'de verilen ve AirPassengers aylık zaman serisi kullanılarak ikili model işbirliğiyle yapılan 15 adet tahmin işleminden, en iyi ilk üç sırasını sırasıyla thetam-nnetar (fn), nnetar-tbats (nt) ve auto.arima-ets (ae) model çiftleri yer paylaşmışlardır.

Çizelge 4.5'de verilen ve AirPassengers aylık zaman serisi kullanılarak üçlü model işbirliğiyle yapılan 20 adet tahmin işleminden, en iyi ilk üç sırasında sırasıyla auto.arima-ets-nnetar (aen), auto.arima thetam-nnetar (afn) ve thetam-nnetar-tbats (fnt) modelleri yer almışlar.

Çizelge 4.6'te verilen ve AirPassengers aylık zaman serisi kullanılarak dördü model işbirliğiyle yapılan 15 adet tahmin işleminden, en iyi ilk üç sırasında sırasıyla afnt, aefn ve aent modelleri yer almışlar.

Çizelge 4.7'te verilen ve AirPassengers aylık zaman serisi kullanılarak beşli model işbirliğiyle yapılan 6 adet tahmin işleminden, en iyi ilk üç sırasında sırasıyla aefnt, afnst ve aenst modelleri yer almışlar.

Çizelge 4.8'te verilen ve AirPassengers aylık zaman serisi kullanılarak altılı model işbirliğiyle yapılan 1 adet tahmin işleminden, en iyi tahmin aefnst modelleri ile yapılmıştır.

İkinci yaklaşımda hibrit model kullanılarak farklı katkıya sahip beş ayrı kategoride yapılan tahmin işlemlerinden en iyi tahmin auto.arima-ets-nnetar (aen) üçlü modeli tarafından %2,81 MAPE değeri ile yapılmıştır. Bu kategorideki işbirlikçi model sıralamaları aen, afnt, fn, aefnt ve aefnst şeklinde olmuştur. İşbirliğinde fazla modelin yer alması daha iyi tahmin anlamına gelmemektedir.

Ayrıca yapılan ikili, üçlü, dördü, beşli ve altılı tahminlerin MAPE ortalamaları sırasıyla %3,636, %3,447, %3,351, %3,320 ve %3,280 olmuştur. Ortalamalardan anlaşıldığı üzere en iyi MAPE sonucu beşli ortalama için elde edilmiştir.

### 5.1.3 Hibrit Model Kullanılarak Eşit Katkıya Sahip Yapılan Tahmin Sonuçları

Çizelge 4.9’de verilen ve AirPassengers aylık zaman serisi kullanılarak eşit katkılı ikili model işbirliğiyle yapılan 15 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla ets- nnetar (en), nnetar-tbats (nt) ve auto.arima-ets (ae) model çiftleri arasında paylaşılmıştır.

Çizelge 4.10’de verilen ve AirPassengers aylık zaman serisi kullanılarak eşit katkılı üçlü model işbirliğiyle yapılan 20 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla auto.arima-ets- nnetar (aen), auto.arima-thetam-nnetar (afn) ve auto.arima-nnetar-tbats (ant) model üçlüsü arasında paylaşılmıştır.

Çizelge 4.11’te verilen ve AirPassengers aylık zaman serisi kullanılarak eşit katkılı dördü model işbirliğiyle yapılan 15 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla auto.arima-ets-nnetar-tbats (aent), auto.arima-thetam-nnetar-tbats (afnt) ve auto.arima- ets-thetam-nnetar (aefn) model dördülüsü arasında paylaşılmıştır.

Çizelge 4.12’te verilen ve AirPassengers aylık zaman serisi kullanılarak eşit katkılı beşli model işbirliğiyle yapılan 6 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla aefnt, aenst afnst) model beşlisi arasında paylaşılmıştır.

Çizelge 4.13’te verilen ve AirPassengers aylık zaman serisi kullanılarak altılı model işbirliğiyle yapılan 1 adet eşit katkılı tahmin işleminden, en iyi tahmin aefnst modelleri ile yapılmıştır.

Üçüncü yaklaşımda hibrit model kullanılarak beş ayrı kategoride yapılan eşit katkılı tahmin işlemlerinden en iyi tahmin auto.arima-ets-nnetar (aen) üçlü modeli tarafından %2,76 MAPE değeri ile yapılmıştır. Bu kategorideki işbirlikçi model sıralamaları aen, aent, en, aefnt ve aefnst şeklinde olmuştur. İşbirliğinde fazla modelin yer alması daha iyi tahmin anlamına gelmemektedir.

Ayrıca yapılan ikili, üçlü, dördü, beşli ve altılı eşit katkılı tahminlerin MAPE ortalamaları sırasıyla %3,596, %3,439, %3,336, %3,308 ve %3,260 olmuştur. Ortalamalardan anlaşıldığı üzere en iyi MAPE sonucu altılı ortalama için elde edilmiştir.

İkinci ve üçüncü yaklaşımda verilen değişken katkılı ve eşit katkılı modeller iş birliği ile yapılan en iyi tahmin işlemlerinde eşit katkılı aen modelinin değişken katkılı aen modelinden 0,05% kadar daha az hata yaptığını söylemek mümkündür.

Değişken katkılı ve eşit katkılı modeller yardımıyla yapılan tahminlerin ikili, üçlü, dördü, beşli ve altılı modellerin kullanıldığı durumlardaki ortalamaları karşılıklı olarak alındığında eşit katkılı modelin daha az hata yaptığını söylemek mümkündür. Daha açık bir ifadeyle ikili modellerin kullanıldığı durumlarda eşit katkılı model 0,04%, üçlü, dördü, beşli ve altılı modellerde ise 0,01% daha az hata yaptığı gözlenmiştir. Genel ortalama ise eşit katkılı yaklaşımın değişken katkılı yaklaşımdan 0,018% kadar daha az hata yaptığı görülmüştür.

#### **5.1.4 Hibrit Model Yardımıyla Çapraz-Doğrulama Kullanılarak Yapılan Tahmin Sonuçları**

Çizelge 4.14’de verilen ve AirPassengers aylık zaman serisi kullanılarak çapraz-doğrulama ikili model işbirliğiyle yapılan 15 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla nnetar-tbats (nt), auto.arima- nnetar (an) ve ets- nnetar (en), model çiftleri arasında paylaşılmıştır.

Çizelge 4.15’de verilen ve AirPassengers aylık zaman serisi kullanılarak çapraz-doğrulama üçlü model işbirliğiyle yapılan 20 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla auto.arima-ets- nnetar (aen), auto.arima-thetam-nnetar (afn) ve auto.arima-nnetar-tbats (ant) model üçlüsü arasında paylaşılmıştır. Buradaki sıralama aynen eşit-katkılı durumda da gözlenmiştir.

Çizelge 4.16’te verilen ve AirPassengers aylık zaman serisi kullanılarak çapraz-doğrulama dördü model işbirliğiyle yapılan 15 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla auto.arima-ets-nnetar-tbats (aent), auto.arima-thetam-nnetar-tbats (afnt) ve auto.arima- ets-thetam-nnetar (aefn) model dördlüsü arasında paylaşılmıştır. Buradaki sıralama aynen eşit-katkılı durumda da gözlenmiştir.

Çizelge 4.17’te verilen ve AirPassengers aylık zaman serisi kullanılarak çapraz-doğrulama beşli model işbirliğiyle yapılan 6 adet tahmin işleminden, en iyi ilk üç sonuç sırasıyla aefnt, aenst afnst model beşlisi arasında paylaşılmıştır. Buradaki sıralama aynen eşit-katkılı durumda da gözlenmiştir.

Çizelge 4.18’te verilen ve AirPassengers aylık zaman serisi kullanılarak altılı model işbirliğiyle yapılan 1 adet eşit katkılı tahmin işleminden, en iyi tahmin aefnst modelleri ile yapılmıştır.

Dördüncü yaklaşımda hibrit model kullanılarak beş ayrı kategoride yapılan çapraz-doğrulama tahmin işlemlerinden en iyi tahmin auto.arima-ets-nnetar (aen) üçlü modeli tarafından %2,80 MAPE değeri ile yapılmıştır. Bu kategorideki işbirlikçi model sıralamaları aen, aent, nt, aefnt ve aefnst şeklinde olmuştur.

Ayrıca yapılan ikili, üçlü, dördü, beşli ve altılı çapraz-doğrulama tahminlerin MAPE ortalamaları sırasıyla %3,66, %3,52, %3,44, %3,39 ve %3,40 olmuştur. Ortalamalardan anlaşıldığı üzere en iyi MAPE sonucu beşli ortalama için elde edilmiştir.

AirPassengers aylık zaman serisi baz alınarak yapılan tahmin işlemlerinde bağımsız ve Hibrit modelleri karşılaştırdığımızda şu sonuçlara ulaşılmaktadır:

1. Bağımsız olarak kullanılan ARIMA, ETS, NNTAR, STL, THETAF VE TBATS modellerine karşılık sırasıyla hibrit ortamda auto.arima (a), ets (e), nnetar (n), stlm (s), thetam (f) ve tbats (t) kullanılmıştır.
2. Bağımsız olarak kullanılan ARIMA, ETS, NNTAR, STL, THETAF VE TBATS modellerin MAPE ortalaması %7,335 olarak hesaplanmıştır. Buna karşılık ikili, üçlü, dördü, beşli ve altılı olarak yapılan Hibrit tahminlerin değişken-katkılı, eşit-katkılı ve çapraz-doğrulama ortalamaları sırasıyla %3,408, %3,390 ve %3,482 olarak hesaplanmıştır. Hibrit modellerde elde edilen üç ortalamanın genel ortalaması da %3,426 olarak hesaplanmıştır.
3. Bu durumda Hibrit modellerin bağımsız modellerden %3,909 kadar daha az hata yaptığını söyleyebiliriz.
4. AirPassengers aylık zaman serisi esas alınarak yapılan tahminlerde, bağımsız modellerin tahmin doğruluğu %92,665 olarak hesaplanırken hibrit modellerle yapılan tahminleri doğruluğu %96,574 olarak hesaplanmıştır.
5. Değişken katkılı, eşit katkılı ve çapraz modeller yardımıyla yapılan tahminlerin ikili, üçlü, dördü, beşli ve altılı modellerin kullanıldığı durumlardaki ortalamaları karşılıklı olarak alındığında eşit katkılı modelin daha az hata yaptığını söylemek mümkündür.

6. Daha açık bir ifadeyle ikili, üçlü, dörtlü, beşli ve altılı Hibrit modellerin kullanıldığı durumlarda eşit-katkılı, değişken katkılı ve çapraz-doğrulama modellerinin MAPE ortalamaları sırasıyla %3,390, %3,408 ve %3,482 olmaktadır. MAPE metriğinin küçük değerleri daha az hata yapmak anlamına geldiğinden dolayı bu durumda en iyi tahminlerin eşit-katkılı hibrit modeller ile yapıldığı açıkça görülmektedir.

## 5.2 Öneriler

Bu çalışmada yapılan analizlerde karşılaştırma için Airpassengers zaman serileri kullanılmıştır. Bunu tercih etmemizin nedeni içerisinde hem mevsimsel hem de trend bileşenlerini barındırıyor olmasının yanı sıra gerçek çalışma verilerinden elde edilmesi idi. Bundan sonra yapılacak çalışmalarda hibrit model yaklaşımları farklı veri setleri kullanılarak sonuçlar karşılaştırılabilir.

## KAYNAKLAR

- Atıcı, R., & Pala, Z. (2021). Prediction of the Ionospheric foF2 Parameter Using R Language Forecasthybrid Model Library Convenient Time. *Wireless Personal Communications*, doi.org/10.1007/s11277-021-09050-6 Prediction, 1–20. <https://doi.org/10.1007/s11277-021-09050-6>
- Atıcı, R., & Pala, Z. (2022). Prediction of the Ionospheric foF2 Parameter Using R Language Forecasthybrid Model Library Convenient Time Series Functions. *Wireless Personal Communications*, 122, 3293–3312. <https://doi.org/10.1007/s11277-021-09050-6>
- Castillo, O., & Melin, P. (2020). Forecasting of COVID-19 time series for countries in the world based on a hybrid approach combining the fractal dimension and fuzzy logic. *Chaos, Solitons & Fractals*, 140, 110242. <https://doi.org/10.1016/J.CHAOS.2020.110242>
- Chang, Z., Zhang, Y., & Chen, W. (2019). Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform. *Energy*, 187, 115804. <https://doi.org/10.1016/J.ENERGY.2019.07.134>
- Du, P., Wang, J., Yang, W., & Niu, T. (2019). A novel hybrid model for short-term wind power forecasting. *Applied Soft Computing*, 80, 93–106. <https://doi.org/10.1016/J.ASOC.2019.03.035>
- Gidon, D., Pei, X., Bonzanini, A. D., Graves, D. B., & Mesbah, A. (2019). *Machine Learning for Real-time Diagnostics of Cold Atmospheric Plasma Sources*. April. <https://doi.org/10.1109/TRPMS.2019.2910220>
- Gjika, E., Ferrja, A., & Kamberi, A. (2019). A study on the efficiency of hybrid models in forecasting precipitations and water inflow Albania case study. *Advances in Science, Technology and Engineering Systems*, 4(1), 302–310. <https://doi.org/10.25046/AJ040129>
- Hyndman, R. J. and Athanasopoulos, G. (2019). *Forecasting: principles and practice*. OTexts, 3rd edition. Retrieved from <https://otexts.com/fpp3/>
- Längkvist, M., Karlsson, L., & Loutfi, A. (2014). A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42(1), 11–24. <https://doi.org/10.1016/J.PATREC.2014.01.008>
- Li, J., Wu, Q., Tian, Y., & Fan, L. (2021). Monthly Henry Hub natural gas spot prices forecasting using variational mode decomposition and deep belief network. *Energy*, 227, 120478. <https://doi.org/10.1016/J.ENERGY.2021.120478>
- Liu, J., Wang, S., Wei, N., Chen, X., Xie, H., & Wang, J. (2021). Natural gas consumption forecasting: A discussion on forecasting history and future challenges. *Journal of Natural Gas Science and Engineering*, 90, 103930. <https://doi.org/10.1016/J.JNGSE.2021.103930>
- Ma, T., Antoniou, C., & Toledo, T. (2020). Hybrid machine learning algorithm and statistical time series model for network-wide traffic forecast. *Transportation Research Part C: Emerging Technologies*, 111, 352–372. <https://doi.org/10.1016/J.TRC.2019.12.022>
- Makridakis, S., Spiliotis, E., Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 13(3),

e0194889.

- Meira, E., Cyrino Oliveira, F. L., & de Menezes, L. M. (2022). Forecasting natural gas consumption using Bagging and modified regularization techniques. *Energy Economics*, 106, 105760. <https://doi.org/10.1016/J.ENECO.2021.105760>
- Pala, Z., Ünlük, İ. H., & Yıldız, E. (2019). Forecasting of electromagnetic radiation time series: An empirical comparative approach. *Applied Computational Electromagnetics Society Journal*, 34(8).
- Pala, Zeydin. (2021). *Examining EMF Time Series Using Prediction Algorithms With R*. 44(2), 223–227.
- Pala, Zeydin, & Atici, R. (2019). Forecasting Sunspot Time Series Using Deep Learning Methods. *Solar Physics*, 294(5). <https://doi.org/10.1007/s11207-019-1434-6>
- Pala, Zeydin, & Özkan, O. (2020). Artificial Intelligence Helps Protect Smart Homes against Thieves. *DÜMF Mühendislik Dergisi*, 11(3), 945–952. <https://doi.org/10.24012/dumf.700311>
- Pala, Zeydin, & Pala, A. F. (2021). Comparison of ongoing COVID-19 pandemic confirmed cases / deaths weekly forecasts on continental basis using R statistical models. *Dicle University Journal of Engineering*, 4, 635–644. <https://doi.org/10.24012/dumf.1002160>
- Pala, Zeydin, & Şana, M. (2020). Attackdet: Combining web data parsing and real-time analysis with machine learning. *Journal of Advances in Technology and Engineering Research*, 6(1), 37–45. <https://doi.org/10.20474/jater-6.1.4>
- Palit, A. K., & Popovic, D. (2005). *Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications (Advances in Industrial Control)*.
- Panigrahi, S., & Behera, H. S. (2017). A hybrid ETSANN model for time series forecasting. *Engineering Applications of Artificial Intelligence*, 66, 49–59. <https://doi.org/10.1016/J.ENGAPPAL.2017.07.007>
- Qiao, W., Huang, K., Azimi, M., & Han, S. (2019). A Novel Hybrid Prediction Model for Hourly Gas Consumption in Supply Side Based on Improved Whale Optimization Algorithm and Relevance Vector Machine. *IEEE Access*, 7, 88218–88230. <https://doi.org/10.1109/ACCESS.2019.2918156>
- Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1), 75–85. <https://doi.org/10.1016/j.ijforecast.2019.03.017>
- Tattar, P. N. (2018). *Hands-on Ensemble Learning with R*. Packt Publishing Ltd.
- Tseng, F. M., Yu, H. C., & Tzeng, G. H. (2001). Applied hybrid grey model to forecast seasonal time series. *Technological Forecasting and Social Change*, 67(2–3), 291–302. [https://doi.org/10.1016/S0040-1625\(99\)00098-0](https://doi.org/10.1016/S0040-1625(99)00098-0)
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)